



**TESIS DOCTORAL**

**VARIABLES ESTRATÉGICAS PARA PRONOSTICAR  
RESULTADOS FINANCIEROS EN PEQUEÑAS EMPRESAS A  
TRAVÉS DE REDES NEURONALES Y ÁRBOLES DE DECISIÓN**

**ANTÓNIO JOSÉ DA SILVA ALMEIDA VIEIRA GONÇALVES**

**2020**





VARIABLES ESTRATÉGICAS PARA PRONOSTICAR  
RESULTADOS FINANCIEROS EN PEQUEÑAS EMPRESAS A  
TRAVÉS DE REDES NEURONALES Y ÁRBOLES DE DECISIÓN

ANTÓNIO JOSÉ DA SILVA ALMEIDA VIEIRA GONÇALVES

DIRECTORES:

Joaquín Texeira Quirós

Maria Do Rosário Texeira F. Justino

**AÑO DE LECTURA**

**2020**





## DEDICATÓRIA

Dedico esta tese de doutoramento aos meus pais, António e Maria Amélia, que me facultaram sempre um porto de abrigo nas minhas decisões, que me ensinaram a viver com os meus erros e com as suas consequências. Sobretudo pelos valores que me ensinaram e que me permitiram alcançar os meus objetivos de forma honesta, persistente, trabalhadora e esforçada.

Dedico esta tese á minha esposa Carla que em todos os momentos me ajudou, apoiou, incentivou e compreendeu. Por ser ela a pessoa mais extraordinária que conheci em toda a minha vida.

Por último, mas não menos importante, dedico esta tese à pessoa que me fez ver a vida de uma forma ainda mais colorida e por quem o amor que sinto é incondicional, a minha filha Maria Margarida.



## EPIGRAFE

“Aprendi que são os pequenos acontecimentos diários que tornam a vida espetacular.”

(William Shakespeare)

“Aprender é a única coisa de que a mente nunca se cansa, nunca tem medo e nunca se arrepende.”

(Albert Schweitzer)



## AGRADECIMENTOS

Os meus agradecimentos são dirigidos ao Prof<sup>o</sup>. Doutor Joaquín Texeira Quirós e à Prof<sup>a</sup>. Doutora Maria do Rosário Justino, orientadores desta Tese de Doutoramento, por todo o seu apoio, confiança e compreensão dados na elaboração e desenvolvimento da mesma.

Um especial agradecimento a todos aqueles que disponibilizaram um pouco do seu tempo e mostraram um interesse genuíno em responder ao questionário elaborado nesta Tese de Doutoramento.

Também um agradecimento a todos os meus colegas de trabalho e amigos que se viram, de alguma forma, privados da minha presença e que não só compreenderam as razões, como ainda me deram motivação.

Um especial agradecimento aos meus pais pelo apoio que me deram em toda esta etapa, assim como em todas as etapas antecessoras.

Por último um especial agradecimento à minha esposa Carla pela forma como me ajuda e apoia todos os dias sem exceção.



## RESUMO

Pretende-se com esta tese analisar a possibilidade de criar modelos preditivos estratégicos utilizando redes neuronais e árvores de decisão. Os modelos deverão permitir a previsão do impacto das estratégias nos resultados financeiros.

Os modelos são criados a partir de dados obtidos por questionário aos gestores acerca das estratégias aplicadas nas suas organizações e a partir dos dados financeiros das organizações declarados ao estado português.

A possibilidade de previsão do impacto das estratégias nos resultados financeiros pode significar uma vantagem significativa, uma vez que estes modelos permitem uma verificação do impacto antes da alocação efetiva de recursos na execução das estratégias.

Os modelos resultantes são alvos de um estudo sobre o seu desempenho preditivo. A conclusão do estudo refere a metodologia utilizada como muito promissora para os objetivos a que se propôs, determinando um erro médio máximo de 25% e com um erro máximo de 30% em mais de 70% do conjunto amostral para avaliação.

Palavras-chave:

Redes Neuronais; Árvores de Decisão; Gestão Estratégica; Modelos Estratégicos; Previsão; Resultados Financeiros





## RESUMEN

Esta tesis pretende analizar la posibilidad de crear modelos predictivos estratégicos utilizando redes neuronales y árboles de decisión. Los modelos deben permitir el pronóstico del impacto de las estrategias en los resultados financieros.

Los modelos se crearán a partir de datos obtenidos mediante cuestionarios a gerentes sobre las estrategias aplicadas en sus organizaciones y a partir de los datos financieros de las organizaciones declaradas al estado portugués.

La posibilidad de pronosticar el impacto de las estrategias en los resultados financieros puede significar una ventaja significativa, ya que estos modelos permiten una verificación del impacto antes de la asignación efectiva de recursos en la ejecución de las estrategias.

Los modelos resultantes son objeto de un estudio sobre su desempeño predictivo. La conclusión del estudio se refiere a la metodología utilizada como muy prometedora para los objetivos para los que se propuso, determinando un error promedio máximo del 25% y con un error máximo del 30% en más del 70% del conjunto de muestras para evaluación.

Palabras clave:

Redes Neuronales; Árboles de Decisión; Gestión Estratégica; Modelos Estratégicos; Pronóstico; Resultados Financieros



## SUMMARY

This thesis intends to analyze the possibility of creating strategic predictive models using neural networks and decision trees. The models should allow the forecast of the impact of the strategies on the financial results.

The models are created from data obtained by questionnaire to managers about the strategies applied in their organizations and from the financial data of the organizations declared to the Portuguese state.

The possibility of forecasting the impact of the strategies on the financial results can mean a significant advantage, since these models allow a verification of the impact before the effective allocation of resources in the execution of the strategies.

The resulting models are the subject of a study on their predictive performance. The achieved results are very promising. The conclusion of the study refers to the methodology used as very promising for the objectives it was proposed for, determining a maximum average error of 25% and with a maximum error of 30% in more than 70% of the sample set for evaluation.

Keywords:

Neural Networks; Decision Trees; Strategic Management; Strategic Models; Forecast; Financial Results



**VARIABLES ESTRATÉGICAS PARA PRONOSTICAR  
RESULTADOS FINANCIEROS EN PEQUEÑAS EMPRESAS A  
TRAVÉS DE REDES NEURONALES Y ÁRBOLES DE DECISIÓN**

**VARIÁVEIS ESTRATÉGICAS PARA PREVISÃO DE  
RESULTADOS FINANCEIROS EM PEQUENAS EMPRESAS  
ATRAVÉS DE REDES NEURONAIS E ÁRVORES DE DECISÃO**



# Índice

DEDICATÓRIA .....	v
EPIGRAFE .....	vii
AGRADECIMENTOS .....	ix
RESUMO .....	xi
RESUMEN .....	xiii
SUMMARY .....	xv
Lista de Figuras .....	xxiii
Lista de Tabelas .....	xxvii
1 INTRODUÇÃO .....	1
1.1 Objeto .....	2
1.2 Objetivos .....	4
1.3 Importância.....	5
1.4 Estrutura .....	6
2 ENQUADRAMENTO TEÓRICO .....	10
2.1 Gestão Estratégica .....	10
2.1.1 Conceito .....	10
2.1.2 Importância .....	10
2.1.3 Estratégia Empresarial em Portugal.....	11
2.1.4 Escolas de Formulação Estratégica.....	13
2.1.5 Níveis de Estratégia .....	30
2.1.6 Princípios Estratégicos.....	32
2.1.7 Formulação e Implementação de Estratégias.....	37
2.1.8 Alianças Estratégicas .....	43
2.1.9 Fatores Críticos de Sucesso .....	44
2.1.10 Estratégias Consideradas .....	45
2.2 Dados Económicos .....	58
2.3 Aplicação de Redes Neurais à Gestão.....	67
2.4 Árvores de Decisão Aplicados á Gestão .....	74
2.5 Previsão de Resultados Financeiros .....	76
2.5.1 Redes Neurais na Previsão.....	78

2.5.2	Árvores de Decisão na Previsão .....	80
3	METODOLOGIA DE INVESTIGAÇÃO.....	81
3.1	Redes Neurais.....	81
3.2	Metodologia de Redes Neurais aplicadas no estudo .....	93
3.2.1	Metodologia .....	93
3.2.2	Algoritmos Utilizados no Estudo.....	95
3.2.3	Topologia e Parametrização.....	98
3.3	Árvores de Decisão .....	101
3.4	Metodologia das Árvores de Decisão aplicadas ao estudo .....	108
3.4.1	Metodologia .....	108
3.4.2	Algoritmo Utilizado no Estudo (RPART) .....	108
4	ESTUDO EMPÍRICO .....	111
4.1	Apresentação do Estudo .....	111
4.1.1	Introdução .....	111
4.1.2	Objetivos Principais .....	112
4.1.3	Hipóteses de Observação .....	112
4.2	Dados.....	113
4.2.1	Questionário.....	113
4.2.2	Dados Financeiros.....	115
4.2.3	Modelos dos Ambientes Estratégicos .....	116
4.2.4	Tratamento dos dados .....	118
4.3	Interpretação dos Resultados.....	126
4.3.1	Gráficos: Comparativo de Valores por Amostra .....	127
4.3.2	Gráficos: Modelação do Conjunto de Testes (Previsão vs Real).....	130
4.3.3	Gráficos: Modelação do Conjunto Treino .....	131
4.3.4	Gráficos: Modelação RNAs vs Árvores de Decisão.....	132
4.3.5	Dados e resultados das amostras.....	134
4.3.6	Dados do Erro Médio e Amplitude dos Resultados do Modelo .....	135
4.3.7	Método de Avaliação dos Modelos.....	136
4.4	Previsão através de Redes Neurais.....	138
4.4.1	Hipóteses de Observação .....	138
4.4.2	Avaliação dos Resultados Gráficos .....	138



4.4.3	Análise dos Resultados obtidos .....	177
4.5	Previsão através de Árvores de Decisão .....	184
4.5.1	Hipóteses de Observação .....	184
4.5.2	Avaliação dos Resultados Gráficos .....	184
4.5.3	Análise dos Resultados obtidos .....	190
4.6	Análise Comparativa dos Resultados .....	191
4.6.1	Modelo Estratégico 2013 .....	191
4.6.2	Modelo Estratégico 2014 .....	191
4.6.3	Modelo Estratégico 2015 .....	192
4.6.4	Modelo Estratégico 2013 – Conjunto Teste 2014 .....	193
4.6.5	Modelo Estratégico 2014 – Conjunto Teste 2015 .....	194
4.6.6	Modelo Estratégico Global .....	196
4.6.7	Conclusão do Estudo Comparativo .....	196
5	CONCLUSÃO, LIMITAÇÕES E SUGESTÕES DE TRABALHO FUTURO .....	198
5.1	Conclusão .....	198
5.2	Limitações .....	200
5.3	Sugestões de Trabalho Futuro .....	201
	REFERÊNCIAS BIBLIOGRÁFICAS .....	203
	Lista de Figuras (Anexos) .....	3
	Lista de Tabelas (Anexos) .....	11
A	ANEXOS .....	15



## Lista de Figuras

FIGURA 2.1: MATRIZ BCG	17
FIGURA 2.2: ANÁLISE SWOT (ADAPTADO WHEELEN E HUNGER, 2002:115)	40
FIGURA 2.3: DADOS ECONÓMICOS - RENDIMENTO DOS PARTICULARES E CONSUMO PRIVADO	58
FIGURA 2.4: DADOS ECONÓMICOS - MERCADO DE TRABALHO	59
FIGURA 2.5: DADOS ECONÓMICOS - PIB, CONSUMO, IMPORTAÇÕES E TX POUPANÇA	60
FIGURA 2.6: DADOS ECONÓMICOS - VOLUME E VARIAÇÃO DO PIB	61
FIGURA 2.7: DADOS ECONÓMICOS - ÍNDICE DE CONFIANÇA	62
FIGURA 2.8: DADOS ECONÓMICOS - PATRIMÓNIOS ANUAIS CONSOLIDADOS	63
FIGURA 2.9: DADOS ECONÓMICOS - ÍNDICE DE PREÇOS NO CONSUMIDOR	64
FIGURA 2.10: DADOS ECONÓMICOS - EMPRÉSTIMOS A FAMÍLIAS.	65
FIGURA 2.11: DADOS ECONÓMICOS - TAXAS DE JURO - EMPRÉSTIMOS A PARTICULARES (CONSUMO)	66
FIGURA 3.1: ESQUEMA DE UM NEURÓNIO BIOLÓGICO	81
FIGURA 3.2: CLASSIFICAÇÃO POR PERCEPTRÃO SIMPLES	83
FIGURA 3.3: REPRESENTAÇÃO GRÁFICA DE UM PERCEPTRÃO BINÁRIO.	83
FIGURA 3.4: REPRESENTAÇÃO GRÁFICA DE UM PERCEPTRÃO GENÉRICO.	84
FIGURA 3.5: REDE NEURONAL DE CAMADA SIMPLES	87
FIGURA 3.6: REDE NEURONAL MULTICAMADA	88
FIGURA 3.7: REPRESENTAÇÃO GRÁFICA DE $F(x)$ E $F'(x)$ PARA $F(x)=\text{SIGMOIDE}(x)$	90
FIGURA 3.8: REPRESENTAÇÃO GRÁFICA DE $F(x)$ E $F'(x)$ PARA $F(x)=\text{TANH}(x)$	91
FIGURA 3.9: TOPOLOGIA DA RNA UTILIZADA NA NEURAL NETWORK CONSOLE	98
FIGURA 3.10 – EXEMPLO DE ÁRVORE DE DECISÃO	102
FIGURA 3.11- EXEMPLO DE UMA ÁRVORE DE DECISÃO PROBABILÍSTICA	104
FIGURA 3.12- REPRESENTAÇÃO GRÁFICA DA FUNÇÃO ENTROPIA(S) VS P+	105
FIGURA 4.1: DISTRIBUIÇÃO DA SOMA ABSOLUTA DAS RESPOSTAS DE 2013	120
FIGURA 4.2: DISTRIBUIÇÃO DA SOMA ABSOLUTA DAS RESPOSTAS DE 2014	120
FIGURA 4.3: DISTRIBUIÇÃO DA SOMA ABSOLUTA DAS RESPOSTAS DE 2015	121
FIGURA 4.4: EXEMPLO - VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	127
FIGURA 4.5: EXEMPLO - VALORES E MÉDIAS POR AMOSTRA C/ERRO<20	127
FIGURA 4.6: EXEMPLO GRÁFICO CONSIDERADO COMO BOA MODELAÇÃO	128
FIGURA 4.7: EXEMPLO GRÁFICO CONSIDERADO COMO MÁ MODELAÇÃO	128
FIGURA 4.8: EXEMPLO - VALORES POR AMOSTRA C/ERRO>30%	129
FIGURA 4.9: EXEMPLO - MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	130
FIGURA 4.10: EXEMPLO: RELAÇÃO ENTRE GRÁFICOS DE MODELAÇÃO	131
FIGURA 4.11: EXEMPLO - MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	131
FIGURA 4.12: EXEMPLO - MODELAÇÃO DO CONJ. DE TREINO.	132
FIGURA 4.13: EXEMPLO: MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL) POR ÁRVORE DE DECISÃO.	133
FIGURA 4.14: EXEMPLO. MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL) POR REDE NEURONAL ARTIFICIAL	133
FIGURA 4.15: EXEMPLO: COMPARATIVO DE VALORES POR AMOSTRA DE ÁRVORE DE DECISÃO.	134
FIGURA 4.16: EXEMPLO: COMPARATIVO DE VALORES POR AMOSTRA DE RNAs	134
FIGURA 4.17: EXEMPLO - NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	134
FIGURA 4.18: DIAGRAMA DO MODELO DE AVALIAÇÃO	137
FIGURA 4.19: ME13NC. VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	140
FIGURA 4.20: ME13NC. VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	140
FIGURA 4.21: ME14NC. VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	141
FIGURA 4.22: ME14NC. VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	141
FIGURA 4.23: : ME15NC. VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	141
FIGURA 4.24: ME15NC. VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	141
FIGURA 4.25: ME13T14NC. VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	142
FIGURA 4.26: ME13T14NC. VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	142

FIGURA 4.27: ME14T15NC. VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	143
FIGURA 4.28: ME14T15NC. VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	143
FIGURA 4.29: ME13R (RPROP-). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	144
FIGURA 4.30: ME13R (RPROP-). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	144
FIGURA 4.31: ME13R (RPROP+). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	145
FIGURA 4.32: ME13R (RPROP+). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	145
FIGURA 4.33: ME13R (SAG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	145
FIGURA 4.34: ME13R (SAG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	145
FIGURA 4.35: ME13R (AVG RPROP). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	146
FIGURA 4.36: ME13R (RPROP AVG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	146
FIGURA 4.37: ME13R (AVG6). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	147
FIGURA 4.38: ME13R (AVG6). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	147
FIGURA 4.39: ME13R (RPROP-/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	147
FIGURA 4.40: ME13R (RPROP-/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	147
FIGURA 4.41: ME13R (RPROP+/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	148
FIGURA 4.42: ME13R (RPROP+/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	148
FIGURA 4.43: ME13R (SAG/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	149
FIGURA 4.44: ME13R (SAG/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	149
FIGURA 4.45: ME14R (RPROP-). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	149
FIGURA 4.46: ME14R (RPROP-). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	149
FIGURA 4.47: ME14R (RPROP+). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	150
FIGURA 4.48: ME14R (RPROP+). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	150
FIGURA 4.49: ME14R (SAG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	151
FIGURA 4.50: ME14R (SAG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	151
FIGURA 4.51: ME14R (AVG RPROP). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	151
FIGURA 4.52: ME14R (RPROP AVG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	151
FIGURA 4.53: ME14R (AVG6). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	152
FIGURA 4.54: ME14R (AVG6). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	152
FIGURA 4.55: ME14R (RPROP-/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	153
FIGURA 4.56: ME14R (RPROP-/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	153
FIGURA 4.57: ME14R (RPROP+/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	154
FIGURA 4.58: ME14R (RPROP+/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	154
FIGURA 4.59: ME14R (SAG/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	154
FIGURA 4.60: ME14R (SAG/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	154
FIGURA 4.61: ME15R (RPROP-). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	155
FIGURA 4.62: ME15R (RPROP-). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	155
FIGURA 4.63: ME15R (RPROP+). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	156
FIGURA 4.64: ME15R (RPROP+). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	156
FIGURA 4.65: ME15R (SAG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	156
FIGURA 4.66: ME15R (SAG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	156
FIGURA 4.67: ME15R (RPROP AVG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	157
FIGURA 4.68: ME15R (RPROP AVG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	157
FIGURA 4.69: ME15R (AVG6). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	158
FIGURA 4.70: ME15R (AVG6). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	158
FIGURA 4.71: ME15R (RPROP-/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	158
FIGURA 4.72: ME15R (RPROP-/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	158
FIGURA 4.73: ME15R (RPROP+/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	159
FIGURA 4.74: ME15R (RPROP+/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	159
FIGURA 4.75: ME15R (SAG/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	160
FIGURA 4.76: ME15R (SAG/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	160
FIGURA 4.77: ME13T14R (RPROP-). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	161
FIGURA 4.78: ME13T14R (RPROP-). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	161

FIGURA 4.79: ME13T14R (RPROP+). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	162
FIGURA 4.80: ME13T14R (RPROP+). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	162
FIGURA 4.81: ME13T14R (SAG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	162
FIGURA 4.82: ME13T14R (SAG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	162
FIGURA 4.83: ME13T14R (RPROP AVG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	163
FIGURA 4.84: ME13T14R (RPROP AVG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	163
FIGURA 4.85: ME13T14R (AVG6). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	164
FIGURA 4.86: ME13T14R (AVG6). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	164
FIGURA 4.87: ME13T14R (RPROP-/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	164
FIGURA 4.88: ME13T14R (RPROP-/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	164
FIGURA 4.89: ME13T14R (RPROP+/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	165
FIGURA 4.90: ME13T14R (RPROP+/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	165
FIGURA 4.91: ME13T14R (SAG/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	166
FIGURA 4.92: ME13T14R (SAG/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	166
FIGURA 4.93: ME14T15R (RPROP-). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	166
FIGURA 4.94: ME14T15R (RPROP-). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	166
FIGURA 4.95: ME14T15R (RPROP). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	167
FIGURA 4.96: ME14T15R (RPROP+). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	167
FIGURA 4.97: ME14T15R (SAG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	168
FIGURA 4.98: ME14T15R (SAG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	168
FIGURA 4.99: ME14T15R (RPROP AVG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	168
FIGURA 4.100: ME14T15R (RPROP AVG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	168
FIGURA 4.101: ME14T15R (AVG6). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	169
FIGURA 4.102: ME14T15R (AVG6). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	169
FIGURA 4.103: ME14T15R (RPROP-/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	170
FIGURA 4.104: ME14T15R (RPROP-/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	170
FIGURA 4.105: ME14T15R (RPROP+/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	170
FIGURA 4.106: ME14T15R (RPROP+/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	170
FIGURA 4.107: ME14T15R (SAG/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	171
FIGURA 4.108: ME14T15R (SAG/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	171
FIGURA 4.109: MEGLOBALR (RPROP-). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	172
FIGURA 4.110: MEGLOBALR (RPROP-). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	172
FIGURA 4.111: MEGLOBALR (RPROP+). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	172
FIGURA 4.112: MEGLOBALR (RPROP+). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	172
FIGURA 4.113: MEGLOBALR (SAG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	173
FIGURA 4.114: MEGLOBALR (SAG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	173
FIGURA 4.115: MEGLOBALR (RPROP AVG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	174
FIGURA 4.116: MEGLOBALR (RPROP AVG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	174
FIGURA 4.117: MEGLOBALR (AVG6). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	174
FIGURA 4.118: MEGLOBALR (AVG6). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	174
FIGURA 4.119: MEGLOBALR (RPROP-/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	175
FIGURA 4.120: MEGLOBALR (RPROP-/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	175
FIGURA 4.121: MEGLOBALR (RPROP+/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	176
FIGURA 4.122: MEGLOBALR (RPROP+/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	176
FIGURA 4.123: MEGLOBALR (SAG/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	176
FIGURA 4.124: MEGLOBALR (SAG/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	176
FIGURA 4.125: ME13T14R (RPROP-/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%. - EXEMPLO DE UM MODELO ACEITE.	182
FIGURA 4.126: ME13T14R (RPROP-/Q). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL) - EXEMPLO DE UM MODELO ACEITE	182
FIGURA 4.127: ME13T14R (RPROP-/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20% - EXEMPLO DE UM MODELO ACEITE	183

FIGURA 4.128: ME13T14R (RPROP-/Q). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL) - EXEMPLO DE UM MODELO ACEITE	183
FIGURA 4.129: ME13T14R (RPROP-/Q). VALORES POR AMOSTRA C/ERRO>30%	183
FIGURA 4.130: ME13ADR. VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	186
FIGURA 4.131: ME13ADR. VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	186
FIGURA 4.132: ME14ADR. VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	187
FIGURA 4.133: ME14ADR. VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	187
FIGURA 4.134: ME15ADR. VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	187
FIGURA 4.135: ME15ADR. VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	187
FIGURA 4.136: ME13T14ADR. VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	188
FIGURA 4.137: ME13T14ADR. VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	188
FIGURA 4.138: ME14T15ADR. VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	189
FIGURA 4.139: ME14T15ADR. VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	189
FIGURA 4.140: MEGLOBALADR. VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	189
FIGURA 4.141: MEGLOBALADR. VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	189
FIGURA 4.142: ME14T15NC. VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	195
FIGURA 4.143: ME14T15R (AVG6). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	195

## Lista de Tabelas

TABELA 2-1: APLICAÇÕES DE RNAs A ÁREAS DE GESTÃO.	72
TABELA 3-1: DADOS DE ORIGEM DA ÁRVORE DE DECISÃO REPRESENTADA NA FIGURA 3.10	105
TABELA 4-1: COMBINAÇÕES DE MODELOS, ALGORITMOS PLATAFORMAS E METODOLOGIAS.	117
TABELA 4-2: REPRESENTAÇÃO NUMÉRICA DAS ESTRATÉGIAS NO QUESTIONÁRIO	119
TABELA 4-3: EXEMPLO DA REPRESENTAÇÃO DOS DADOS DAS EMPRESAS	119
TABELA 4-4: DADOS DO COMPORTAMENTO ESTRATÉGICO DOS GESTORES	121
TABELA 4-5: NÚMERO DE AMOSTRAS COM COMPORTAMENTO VÁLIDO	122
TABELA 4-6: NÚMERO DE AMOSTRAS ELEGÍVEIS PARA MODELAÇÃO	123
TABELA 4-7: FATOR DE DIVISÃO DO VALOR DAS ENTRADAS DAS RNAs(R)	125
TABELA 4-8: EXEMPLO VALORES DO QUESTIONÁRIO	125
TABELA 4-9: EXEMPLO DE VALORES APÓS DIVISÃO POR FATOR (ME14 RProp-)	125
TABELA 4-10: EXEMPLO VALORES DO QUESTIONÁRIO NORMALIZADOS	126
TABELA 4-11: CLASSIFICAÇÃO DO COMPORTAMENTO GRÁFICO DOS VALORES PREVISTOS	129
TABELA 4-12: EXEMPLO - NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	134
TABELA 4-13: EXEMPLO - VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	135
TABELA 4-14: ME13NC - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	140
TABELA 4-15: ME14NC - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	141
TABELA 4-16: ME15NC - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	142
TABELA 4-17: ME13T14NC - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	142
TABELA 4-18: ME14T15NC - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	143
TABELA 4-19: ME13R (RProp-) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	144
TABELA 4-20: ME13R (RProp+) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	145
TABELA 4-21: ME13R (SAG) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	146
TABELA 4-22: ME13R (RProp AVG) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	146
TABELA 4-23: ME13R (AVG6) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	147
TABELA 4-24: ME13R (RProp-/Q) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	148
TABELA 4-25: ME13R (RProp+/Q) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	148
TABELA 4-26: ME13R (SAG/Q) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	149
TABELA 4-27: ME14R (RProp-) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	150
TABELA 4-28: ME14R (RProp+) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	150
TABELA 4-29: ME14R (SAG) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	151
TABELA 4-30: ME14R (RProp AVG) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	152
TABELA 4-31: ME14R (AVG6) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	152
TABELA 4-32: ME14R (RProp-/Q) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	153
TABELA 4-33: ME14R (RProp+/Q) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	154
TABELA 4-34: ME14R (SAG/Q) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	155
TABELA 4-35: ME15R (RProp-) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	155
TABELA 4-36: ME15R (RProp+) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	156
TABELA 4-37: ME15R (SAG) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	157
TABELA 4-38: ME15R (RProp AVG) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	157

TABELA 4-39: ME15R (AVG6) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	158
TABELA 4-40: ME15R (RPROP-/Q) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	159
TABELA 4-41: ME15R (RPROP+/Q) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	159
TABELA 4-42: ME15R (SAG/Q) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	160
TABELA 4-43: ME13T14R (RPROP-) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	161
TABELA 4-44: ME13T14R (RPROP+) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	162
TABELA 4-45: ME13T14R (SAG) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	163
TABELA 4-46: ME13T14R (RPROP AVG) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	163
TABELA 4-47: ME13T14R (AVG6) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	164
TABELA 4-48: ME13T14R (RPROP-/Q) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	165
TABELA 4-49: ME13T14R (RPROP+/Q) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	165
TABELA 4-50: ME13T14R (SAG/Q) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	166
TABELA 4-51: ME14T15R (RPROP-) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	167
TABELA 4-52: ME14T15R (RPROP+) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	167
TABELA 4-53: ME14T15R (SAG) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	168
TABELA 4-54: ME14T15R (RPROP AVG) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	169
TABELA 4-55: ME14T15R (AVG6) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	169
TABELA 4-56: ME14T15R (RPROP-/Q) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	170
TABELA 4-57: ME14T15R (RPROP+/Q) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	171
TABELA 4-58: ME14T15R (SAG/Q) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	171
TABELA 4-59: MEGLOBALR (RPROP-) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	172
TABELA 4-60: MEGLOBALR (RPROP+) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	173
TABELA 4-61: MEGLOBALR (SAG) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	173
TABELA 4-62: MEGLOBALR (RPROP AVG) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	174
TABELA 4-63: MEGLOBALR (AVG6) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	175
TABELA 4-64: MEGLOBALR (RPROP-/Q) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	175
TABELA 4-65: MEGLOBALR (RPROP+/Q) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	176



TABELA 4-66: MEGLOBALR (SAG/Q-) - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	177
TABELA 4-67: AVALIAÇÃO GLOBAL DOS MODELOS COM SUCESSO (RNAs).	178
TABELA 4-68: AVALIAÇÃO GLOBAL DOS MODELOS SEM SUCESSO (RNAs)	178
TABELA 4-69: AVALIAÇÃO GLOBAL DOS MODELOS PASSIVEIS DE AVALIAÇÃO MAIS DETALHADA (RNAs)	179
TABELA 4-70: AVALIAÇÃO DOS MODELOS (PRINCÍPIO DA AMPLITUDE) (RNAs)	180
TABELA 4-71: AVALIAÇÃO ME13T14 (RPROP+/Q ) - EXEMPLO DE UM MODELO ACEITE	182
TABELA 4-72: ME13ADR - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	186
TABELA 4-73: ME14ADR - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	187
TABELA 4-74: ME15ADR - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	188
TABELA 4-75: ME13T14ADR - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	188
TABELA 4-76: ME14T15ADR - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	189
TABELA 4-77: MEGLOBALADR - AVALIAÇÃO VISUAL DOS GRÁFICOS COMPARATIVOS DE VALORES POR AMOSTRA	190
TABELA 4-78: AVALIAÇÃO GLOBAL DOS MODELOS GERADOS POR ADS.	190
TABELA 4-79: COMPARAÇÃO DAS AVALIAÇÕES DO MODELO ME13	191
TABELA 4-80: COMPARAÇÃO DAS AVALIAÇÕES DO MODELO ME14	192
TABELA 4-81: COMPARAÇÃO DAS AVALIAÇÕES DO MODELO ME15	193
TABELA 4-82: COMPARAÇÃO DAS AVALIAÇÕES DO MODELO ME13T14	193
TABELA 4-83: COMPARAÇÃO DAS AVALIAÇÕES DO MODELO ME14T15	194
TABELA 4-84: COMPARAÇÃO DAS AVALIAÇÕES DO MODELO MEGLOBAL	196

### 1 INTRODUÇÃO

Atualmente o mundo empresarial sofre de um dinamismo nunca antes observado. Esse dinamismo induz uma dificuldade extra na gestão como utensílio de sobrevivência e expansão dos negócios. A importância da componente estratégica empresarial está presente no desempenho obtido pelas empresas.

Pode considerar-se uma analogia entre uma empresa e um automóvel. Imagine-se um automóvel numa ilha com diversas localidades definidas e estradas a ligar essas localidades, mas sem placas direcionais informativas.

Ter uma empresa sem gestão seria como ter-se o automóvel sem volante, poder-se-ia colocar o automóvel em movimento, mas não se poderia dar-lhe a direção pretendida.

Caso se colocasse um volante no automóvel, analogamente uma empresa com gestão, poder-se-ia dar direção ao automóvel em movimento, mas não se saberia se a direção a seguir seria a correta, nem para onde se encaminhava, eventualmente poder-se-ia chegar ao destino desejado mas provavelmente não de uma forma rápida ou eficiente.

Existe a possibilidade de a gestão estratégica ser vista como um mapa, ou seja, poder-se-ia verificar quais os caminhos que poderiam ser seguidos para chegar ao destino desejado.

Uma ferramenta de modelação de estratégias versus resultados, seria como ter um GPS no automóvel, ou seja, seria uma ferramenta de auxílio que permitiria saber o melhor caminho a percorrer consoante os objetivos, quer fosse na poupança de gasolina, distância a percorrer ou o caminho mais rápido. Logo uma ferramenta, que permita modelar um ambiente estratégico de forma bem definida e consistente, poderia permitir às organizações perceber o melhor caminho estratégico a seguir para otimizar os seus recursos e ou o seu plano estratégico.

É sobre este conceito que incide esta tese de doutoramento, criando modelos e analisando a metodologia e a possibilidade de se conseguir criar uma ferramenta que permita prever o impacto das estratégias aplicadas numa organização nos seus resultados financeiros, nomeadamente no volume de negócios.

### 1.1 Objeto

O objeto de estudo desta dissertação reparte-se sobretudo sobre dois tópicos: Uma ênfase especial sobre a gestão estratégica e uma breve descrição sobre os métodos utilizado para construção dos modelos, as redes neuronais e as árvores de decisão, normalmente associadas à área de inteligência artificial de informática e tecnologias de informação.

O estudo sobre o qual incide esta tese de doutoramento foca-se nas estratégias utilizadas pelas microempresas e pequenas empresas de acordo com os seus resultados. Segundo o IAPMEI, considera-se microempresas as empresas com menos de 10 trabalhadores e volume de negócios inferiores ou iguais a 2 milhões de euros, e por pequenas empresas as empresas com menos de 50 trabalhadores e volume de negócios inferior ou igual a 10 milhões de euros. Neste estudo contemplou-se empresas dos 5 aos 50 trabalhadores e com um volume de negócios até 10 milhões de euros.

As estratégias utilizadas pelas empresas alvo de estudo foram obtidas através de um questionário aos responsáveis pela gestão e definição de estratégias. O questionário incide sobre as estratégias utilizadas pelas empresas em questão nos anos 2013, 2014 e 2015.

Com as respostas ao questionário deverá ser possível, através das redes neuronais e árvores de decisão, modelar as estratégias e correlaciona-los com os resultados financeiros. Os modelos a serem construídos terão como âmbito a modelação de ambientes estratégicos que permitam a previsão de resultados financeiros, nomeadamente o volume de negócios, através das estratégias aplicadas.

Para modelar resultados calculados posteriormente ao volume de negócio enfrenta-se variados problemas que estão associados a variáveis intrínsecas da organização, por exemplo o nível de desempenho dos colaboradores, dívida financeira da empresa ou mesmo o modelo de taxaço de impostos. Resultados financeiros como os resultados operacionais, ebitda ou resultados líquidos por ter associadas características que podem ser independentes das estratégias e por isso extremamente difíceis ou mesmo impossíveis de modelar utilizando apenas as estratégias aplicadas na organização.

Apesar de estar previsto que esta tese seja apenas finalizada em 2019, existem vários problemas quanto à obtenção de dados mais recentes. Pelo que se expõe os motivos que levaram a decisão de utilizar dados de 2012 a 2015.

### **Estabilidade no ambiente económico**

Aquando o começo do estudo em 2016 existiu uma breve análise ao ambiente económico e percebeu-se que entre os anos de 2012 e 2015 o ambiente económico em Portugal era de um ambiente económico vindo de uma recessão provocada por uma elevada dívida pública que culminou em medidas de austeridade e aumento de impostos. Os indicadores inerentes ao comportamento dos consumidores e das famílias tiveram um comportamento semelhante nestes 4 anos. Existiu alguma estabilidade, apesar de se verificar um pequeno crescimento entre 2014 e 2015. Já nos finais de 2015 e prolongando-se até 2019 existiu um crescimento da economia em Portugal. Para a modelação dos ambientes estratégicos é fundamental que o estudo seja feito em anos com comportamento do ambiente económico semelhante. O próprio comportamento dos consumidores em ambientes de crescimento económico podem ter um impacto significativo nos resultados financeiros sendo que torna difícil separar o impacto induzido pelo crescimento económico e o impacto induzido pelas estratégias utilizadas pelas organizações. Logo os modelos estariam sujeitos a ruído provocado pelo comportamento dos consumidores inerente ao crescimento económico.

### **Disponibilidade dos resultados financeiros**

Os resultados financeiros das organizações de um Ano X apenas são disponibilizados por volta de setembro do Ano X+1. O que leva a que na altura do começo do estudo em inícios de 2017 os dados financeiros disponíveis eram os dados financeiros de 2015. Os dados financeiros de 2016 apenas seriam disponibilizados na segunda metade de 2017.

### **Resistência na adesão do inquérito**

Foi notório o desconforto dos gestores em responderem a perguntas que envolviam respostas sobre as estratégias das organizações que geriam. Muitos dos gestores das empresas negaram-se em responder ao inquérito, justificando a necessidade de confidencialidade das estratégias, quer do que foi planeado quer da sua implementação. Uma tentativa de ultrapassar este problema foi

inquirir os gestores sobre estratégias utilizadas em anos prévios e cujos resultados financeiros já eram conhecidos

Desta forma e verificando que nos anos de 2017 e 2018 só se teria acesso aos dados, necessários para o estudo, no máximo do ano de 2016. Por este motivo não se conseguiria ter 3 anos consecutivos com um comportamento económico semelhante e de forma a permitir a avaliação de modelos criados com dados de anos diferentes. Decidiu-se utilizar os dados de 2012 a 2015 para permitir uma análise mais coerente e precisa dos resultados obtidos.

### 1.2 Objetivos

O objetivo do estudo foca-se na possibilidade de construir modelos previsionais. Sendo que o estudo centra-se na construção de modelos de previsão de resultados através de estratégias. Estes modelos devem ter como entrada o nível de aplicação das estratégias a utilizar no respetivo ano. Como saídas deve ter a variação dos resultados financeiros esperados pela utilização das estratégias definidas na entrada.

Para o estudo empírico inerente a esta tese de doutoramento considerou-se algumas variáveis estratégicas genéricas que podem existir em quase todos os sectores de atividade e em qualquer organização, seja ela de dimensões reduzidas ou significativas. Desta forma optou-se por focar o enquadramento teórico na descrição destas estratégias.

Um modelo pode ser visto como uma função de aridade  $n$ , chamado de parâmetros de entrada e que têm um resultado que pode ter uma aridade  $m$ :

$$f(x_1, x_2, x_3, \dots, x_n) = [y_1, y_2, \dots, y_m]$$

Define-se ariedade de uma função como o número de parâmetros de entrada, por exemplo uma função de ariedade 2 significa que tem 2 parâmetros de entrada, como por exemplo  $f(x_1, x_2)$ .

As metodologias a aplicar para criação dos modelos estão intrinsecamente ligadas à área de estudos computacionais, mais especificamente à área de Inteligência Artificial (IA). Sendo que se utilizam Redes Neurais Artificiais (RNA) e Árvores de Decisão (AD) para construir os modelos, e assim permitir a análise sobre os resultados independentes de cada modelo.

É objetivo deste estudo fazer uma análise comparativa entre as duas metodologias utilizadas, e tirar conclusão sobre o desempenho, vantagens e desvantagens de cada método. O desempenho

está fortemente ligado ao que se considera como admissível como erro nestes modelos previsionais. Na definição desta admissibilidade deve-se ter em conta que não foram encontrados estudos relevantes sobre a aplicação das estratégias a modelos estratégicos previsionais para prever o seu impacto nos resultados e que o objetivo do estudo é demonstrar a possibilidade de tais modelos puderem ser criados a partir das estratégias aplicadas.

Este é um estudo inovador, uma vez que nada foi encontrado acerca da modelação de ambientes estratégicos utilizando as estratégias aplicadas de empresas com o objetivo de prever os resultados. Este estudo pretende verificar se, através de redes neuronais e árvores de decisão, é possível prever a alteração do volume de negócios através das variáveis estratégicas aplicadas. A conclusão positiva também significa que as estratégias aplicadas podem ter um impacto, embora que possa não ser linear, nos resultados financeiros das empresas.

Toda a envolvente neste estudo foi cuidadosamente analisada para que as conclusões sejam fidedignas e uma conclusão positiva pode significar um impacto significativo na arte de prever resultados financeiros. Note-se que o estudo é pioneiro e é possível depreender que um estudo que tenha como objetivo um grande grau de precisão estaria inerente a uma quantidade de recursos consideráveis, quer humanos quer temporais. Por este motivo a precisão definida como necessária a alcançar é semelhante à precisão conseguida por outros métodos de previsão de resultados financeiros, como por exemplo a previsão baseada em series temporais.

### 1.3 Importância

O uso de métodos estratégicos em conjunto com a gestão tradicional de uma organização é de uma importância considerável e induz o planeamento, assim como a antevisão de problemas e obstáculos inerentes aos caminhos seguidos pela organização na tentativa de alcançar as suas metas e objetivos.

Uma organização pode ganhar uma competitividade extra, e sobrepor-se aos seus concorrentes, estabelecendo uma diferença que valoriza os seus produtos ou serviços da perspetiva dos consumidores. No entanto, esta diferença deve ser mantida para que essa vantagem competitiva perdure continuamente num enquadramento temporal [1].

## INTRODUÇÃO

Apesar da teoria económica tradicional preveja que uma certa vantagem competitiva possa ter um tempo de vida curto, devido ao facto de os concorrentes tenderem a adaptar-se, na realidade as vantagens competitivas deve durar mais do que a teoria económica tradicional prevê [2, p. 12].

A importância da estratégia também está inerente ao dinamismo, do mercado, verificado hoje em dia. Tal como numa batalha, onde o movimento e a posição das tropas são executados de acordo com o movimento dos adversários, a gestão estratégica também tem de ter em conta as possíveis alterações comportamentais dos concorrentes e preparar a organização para responder adequadamente e em tempo útil. Por outras palavras, todo o dinamismo inerente ao mercado influencia a organização e as suas estratégias.

Os gestores e conselheiros de gestão usam dados e informação aliados aos algoritmos analíticos de previsão como uma possibilidade de análise e discernimento nas suas decisões. Este método pode trazer mais valias para as organizações corporativas [3, p. 19]. Os gestores tentam reduzir a incerteza e fazer estimativas mais precisas do que pode acontecer num enquadramento temporal futuro. Este é o principal objetivo das previsões [4, p. 165].

O pensamento estratégico envolve antecipar alterações. Os produtos, serviços e processos operacionais são desenhados de acordo com as alterações expectáveis do comportamento dos clientes. A flexibilidade é importante e a habilidade para responder em tempo útil é crítica como resultado das exigências dos novos conceitos da gestão induzida pelo comércio eletrónico, pela rapidez de aproximação de produto ao mercado e pela produção flexível [5, p. 6].

Uma ferramenta que permita, de forma informada, prever, avaliar e adaptar as estratégias, a serem seguidas pela organização, antes de serem implementadas pode levar a uma vantagem significativa sobre os seus concorrentes. Este estudo permite avaliar o método de modelação proposto que poderá servir de base para desenvolver tal ferramenta como é referido no objeto de estudo.

### 1.4 Estrutura

A estrutura escolhida para esta tese foi definida em 6 partes:

- 1) Introdução
- 2) Enquadramento teórico que descreve a teoria inerente ao estudo executado.
- 3) Metodologia de Investigação que se foca nos conceitos, base científica e algoritmos dos métodos utilizados no estudo empírico.

## INTRODUÇÃO

- 4) Estudo Empírico associado ao objetivo da tese e a Análise comparativa entre os resultados dos métodos utilizados no estudo empírico.
- 5) Conclusão, limitações e possível trabalho futuro sobre o estudo empírico.
- 6) Anexos onde são apresentados os resultados, assim como os dados, inerentes a toda a formulação do estudo empírico.

Com o enquadramento teórico pretende-se disponibilizar o conhecimento para uma compreensão total, de forma rápida e simples, sobre os processos utilizados no estudo elaborado, assim como as bases para uma compreensão do estudo sobre a hipótese levantada. O enquadramento teórico é dividido em 5 secções que deverão fomentar os seguintes conhecimentos:

- Gestão Estratégica: Descrição dos fundamentos da gestão estratégica aplicadas na elaboração do estudo empírico, nomeadamente na elaboração do questionário.
- Dados Económicos: Uma breve descrição sobre o estado do ambiente económico em Portugal durante os anos inerentes ao estudo realizado.
- Aplicação das RNAs à Gestão: Estudo do estado de arte da aplicação da metodologia baseada em RNAs no apoio da gestão das organizações.
- Árvores de Decisão aplicados à Gestão: Estudo do estado de arte da aplicação de sistemas de decisão no apoio da gestão das organizações.
- Previsão de Resultados Financeiros: Elaboração de uma compilação dos métodos utilizados para previsão de resultados financeiros de uma organização.

A metodologia de investigação descreve a base científica inerente à criação de modelos através de árvores de decisão e redes neuronais. Nesta secção são apresentados os conceitos básicos de funcionamento de cada uma das metodologias utilizadas na criação dos modelos. É nesta secção que se descreve, também, a base matemática e os algoritmos inerentes aos métodos utilizados, quer em redes neuronais quer em árvores de decisão. Esta secção é subdividida em duas subsecções:

- Redes Neuronais Artificiais: Descrição do conceito e funcionamento da metodologia das redes neuronais utilizadas na modelação dos modelos necessários para elaboração do estudo.



## INTRODUÇÃO

- Árvores de Decisão: Descrição o conceito e funcionamento da metodologia das Árvores de Decisão utilizadas na modelação dos modelos necessários para elaboração do estudo.

Com o estudo empírico pretende-se a descrição plena e detalhada sobre as hipóteses levantadas, assim como todo o processo utilizado para verificação e demonstração dessas hipóteses. O estudo empírico foca-se nas experiências realizadas através das metodologias e plataformas escolhidas para realização do estudo. Esta secção tem 6 sub-secções:

- Apresentação do Estudo: Descrição do estudo realizado, assim como os objetivos principais e as hipóteses de observação. Por último descreve-se a justificação do intervalo temporal escolhido para realização do estudo.
- Dados: Descrição dos dados utilizados no estudo: o questionário, dados financeiros, assim como os modelos criados. É aqui que também se descreve o tratamento dos dados necessário para realização do estudo.
- Interpretação dos Resultados: Descrição da forma e os métodos como os resultados são avaliados no estudo empírico. Definição dos limites e do que se considera satisfatório para um ambiente ser considerado como aceitável.
- Previsão através das Redes Neurais: Descrição dos resultados obtidos e avaliação sobre o desempenho dos modelos criados através da metodologia das RNAs.
- Previsão através de Árvores de Decisão: Descrição dos resultados obtidos e avaliação sobre o desempenho dos modelos criados através da metodologia das ADs.
- Análise Comparativa: Comparação entre os resultados e desempenho de cada um dos métodos utilizados. Esta análise permite uma visualização geral do desempenho específico de cada um dos modelos criados por metodologia e plataforma. Será abordada uma conclusão primária sobre os diferentes métodos.

A conclusão insere-se no seguimento do estudo empírico e análise comparativa de forma a permitir uma perspetiva consequencial sobre o estudo e que deverá ser perfeitamente compreensível após a leitura do enquadramento teórico e do desenvolvimento do estudo. Neste capítulo serão

## INTRODUÇÃO

identificadas as limitações dos modelos e do seu método de criação, assim como sugestões de trabalho que poderá ser feito posteriormente.

A última parte será os anexos, onde estará colocado todo o material inerente ao estudo, tabelas de dados utilizadas, todas as imagens geradas, desde os resultados de desempenho dos modelos à topografia das árvores de decisão. Os objetivos principais desta secção é permitir a reprodução das experiências executadas, assim como a possibilidade de verificar com detalhe os resultados obtidos. Correspondendo a seguinte estrutura:

- Questionário
- Dados Económicos
- Resultados Experimentais
- Gráficos e Tabelas
- Árvores de Decisão
- Desenvolvimento de Software

A parte dos Anexos demonstra todo o estudo de forma clara, mas sem as explicações existentes na parte principal. São apresentados os dados utilizados para modelação, discriminados por modelo. Assim como as respostas dos gestores ao questionário e as alterações dos resultados financeiros de ano para ano. Ambos em forma de entradas ou saídas providenciadas para treino das redes neuronais e das árvores de decisão. É também nos Anexos que é colocado todos os resultados em forma de valores ou gráficos, como as topologias e código de programação feito especificamente para permitir a realização das experiências.

## 2 ENQUADRAMENTO TEÓRICO

### 2.1 Gestão Estratégica

#### 2.1.1 Conceito

A palavra estratégia é derivada do termo grego *strategos*, cujo significado estava inerente ao líder ou general das tropas militares. A função deste líder baseava-se na responsabilidade de dispor tropas e combinar manobras para que se alcançasse a vitória.

Freire defende que “a estratégia é frequentemente conotada com a formulação de um plano que reúne, de uma forma integrada, os objetivos, políticas e ações da organização com vista a alcançar o sucesso” [6, p. 18].

Segundo Porter, o conceito de estratégia está inerente à necessidade de criação de uma posição vantajosa sob os seus concorrentes, através de um conjunto de ações. Porter evidencia ainda que a essência da estratégia é sobretudo escolher caminhos diferentes dos seus concorrentes [1].

René Cordeiro define o processo de raciocínio estratégico como “Processo e metodologia de pensamento que objetiva e permite a articulação e assunção coletiva e consensual da Visão de uma empresa e do seu Perfil Estratégico (a visão transformada em alvo).” [7, p. 247]

A Gestão Estratégica permite às organizações planear e traçar caminhos de acordo com os seus objetivos. Na realidade a estratégia é definida por um conjunto de ações planeadas e executadas de forma a movimentar a organização em direção aos seus objetivos, prevendo comportamentos internos à organização, por exemplo comportamentos financeiros ou humanos, assim como comportamentos externos, como é o caso dos comportamentos do mercado ou dos consumidores.

#### 2.1.2 Importância

A utilização de métodos estratégicos aliados à gestão global de uma organização revela-se de uma importância extrema e induz um planeamento, assim como permite a previsão de problemas e obstáculos inerentes aos caminhos a percorrer, pelas organizações, que levam aos seus objetivos.

Uma empresa pode superar os seus adversários estabelecendo uma diferença que valorize os seus produtos ou serviços na perspetiva dos consumidores. Contudo essa diferença deve ser mantida de forma a criar uma vantagem competitiva temporalmente continua [1].

A competitividade estratégica pode ser alcançada a partir da formulação e implementação de uma estratégia que crie valor. A estratégia deve ser utilizada para ganhar uma vantagem competitiva

que permita explorar o núcleo de competências da organização, através de um conjunto de compromissos e ações previamente delineadas [8, p. 6].

Por sua vez, Freire(2008) faz referência que “a estratégia pode ser definida com o conjunto de decisões e ações da empresa que, de uma forma consistente, visam proporcionar aos clientes mais valor que o oferecido pela concorrência.” [6, p. 22]

A importância da estratégia está também inerente ao dinamismo do mercado, verificado hoje em dia. Tal como numa batalha, onde o deslocamento e a posição tomada pelas tropas eram executados de acordo com os movimentos do adversário, também a gestão estratégica tem de tomar em consideração possíveis alterações no comportamento dos concorrentes e estar preparada para responder quer de forma adequada, quer em tempo útil. Ou seja, todo o dinamismo inerente ao mercado transita para as organizações e suas estratégias.

O processo estratégico deve levar a organização a criar valor para os seus acionistas e que este processo consiste num conjunto de ações que permita o aumento do desempenho empresarial, providenciando uma vantagem competitiva em relação aos seus concorrentes [9].

A criação de valor para o cliente através de estratégias adequadas, deve permitir à organização obter melhores resultados de forma a sobreviver ou mesmo a crescer e desta forma criar valor para os seus *stakeholders*. Desta forma a importância da estratégia está diretamente ligada à capacidade de sobrevivência e crescimento da organização, de acordo com os seus objetivos.

### **2.1.3 Estratégia Empresarial em Portugal**

A competitividade estrutural portuguesa depende sobretudo da capacidade de as empresas renovarem as estratégias, assim como o desenvolvimento de estratégias orientadas para a inovação, marca e qualidade. A passividade estratégica pode levar a um subaproveitamento das atividades, gerando baixo valor. O não aproveitamento da criatividade e capacidade de trabalho leva a que as organizações portuguesas desperdicem a sua principal vantagem competitiva [6, p. 559].

A estratégia organizacional tem importância na performance pessoal e onde o papel dos colaboradores é fundamental. A comunicação deve constituir um ponto a se ter em conta e onde o equilíbrio, evitando o excesso ou a ausência, da informação. Sendo que a falta deste equilíbrio pode levar à deturpação da comunicação organizacional [10, p. 232].

Freire defende que “o verdadeiro entrave à modernização do país não reside em meras diferenças de dimensão ou de capitalização, reside sobretudo nas diferenças de capacidade de gestão entre empresas competitivas e não competitivas.” [6, p. 560].

Um fator que limita a capacidade de melhoramento e otimização estratégica das organizações portuguesas é a insuficiência de tecnologias próprias. A vantagem competitiva pode ser fortemente prejudicada pelo facto de as organizações não procederem a inovações sistemáticas sobre os seus produtos ou processos [6, p. 562].

Outro fator que pode ter implicações negativas é o facto de a maioria dos estudantes de gestão, os futuros gestores entrarem no mercado terem pouca ou nenhuma experiência e que basicamente confiam nos conhecimentos adquiridos nas instituições de ensino. Devendo existir um processo que relacione a prática com a teoria aprendida moldando a experiência às necessidades do mercado [11, p. 51].

No entanto, a consultadoria de gestão pode ser configurada apesar da diversidade de atividades existentes que podem ser utilizadas como suporte para funções estratégicas e operacionais das organizações. Sendo que operando como um serviço pode apenas fazer recomendações ou mesmo indo mais longe e tomar parte ativa na implementação das recomendações [12, p. 49].

As empresas portuguesas tendem a seguir uma estratégia de localização que lhes permita aproveitar os recursos existentes que sejam favoráveis às suas atividades. Este facto permite a criação de vantagens competitivas internas devido à aglomeração de empresas no mesmo local, e á interação entre elas [13, p. 14].

Devido ao facto de não existir uma forte componente de inovação e que ao existir uma limitação da renovação de modelos e expansão da matriz produtos-mercados, muitas das organizações nacionais optam pela diversificação não relacionada. Muitos dos casos de insucesso estratégico revelaram que existiu uma simples procura de mercados e negócios atrativos sem existir uma preocupação com a posição competitiva [6, p. 263].

As empresas utilizam também uma estratégia de internacionalização de forma a colmatar as dificuldades induzidas para sobreviver em mercados com fracas oportunidades. Desta forma tentam aproveitar as suas vantagens em mercados estrangeiros [13, p. 49].

### 2.1.4 Escolas de Formulação Estratégica

Mintzberg, Ahlstrand e Lampel(1998) identificam, no seu livro *Safari Strategy*, dez tipos de escola e a relação que usufruem com a modelação estratégica. Nos próximos subcapítulos irá ser descrito um resumo dos conceitos e características de cada uma destas escolas.

#### *Escola de Design*

A Escola de *Design* é identificada como a mais influente escola na perspetiva do processo de formação estratégica. Esta escola defende a criação de estratégias a partir de uma análise de forças e fraquezas correlacionadas com oportunidades e ameaças. Uma análise globalmente conhecida, que assenta nestes pressupostos, é a análise SWOT [14, p. 24].

As origens da Escola de Design remontam aos finais da década de 50 e princípios da década de 60 na Universidade da Califórnia e do M.I.T. com o desenvolvimento de dois livros considerados de grande influência: “Leadership in Administration” de Philip Selznick, em 1957, e “Strategy and Structure” de Alfred Chandler, em 1962. Em 1967 surgiu um livro intitulado “Business Policy: Text and Cases” desenvolvido pelo grupo de Gestão Geral da *Harvard Business School*, que causou um impulso importante na influência desta escola.

Power, Grannon, McGinnis e Schweiger referem um conjunto de variáveis ambientais a ter em consideração na formulação das estratégias [15, p. 38]:

- a) Alterações sociais
- b) Alterações governamentais
- c) Alterações económicas
- d) Alterações competitivas ou concorrenciais
- e) Alterações nos fornecedores
- f) Alterações de mercado

Um conjunto de características a ter em conta na avaliação de forças e ameaças [15]:

- a) Marketing
- b) Investigação e Desenvolvimento
- c) Gestão de Sistemas de informação
- d) Gestão de equipas
- e) Organização Operacional

- f) Gestão Financeira
- g) Recursos Humanos

Sabe-se que existem alguns pontos a ter em consideração na formulação de estratégias [14, pp. 29-33]:

- a) A formulação estratégica deve ser um processo consciente e deliberado.
- b) A responsabilidade da formulação estratégica deve estar no estratega, ou seja, o CEO (Chief Executive Officer)
- c) O modelo de formulação estratégica deve ser simples e informal
- d) As estratégias devem ser específicas e não generalizadas.
- e) O processo de formulação estratégica está completo quando as estratégias estão devidamente delineadas.
- f) As estratégias devem ser explícitas.
- g) As estratégias estão devidamente formuladas apenas quando são únicas, explícitas, simples e consistentes e só aí podem ser implementadas.

É definido que existem quatro condições fundamentais de encorajamento para utilização da formulação através do modelo da escola de design [14, pp. 43-44]:

- a) Uma pessoa deve ter conhecimento de toda a informação relevante sobre a formulação estratégica
- b) Essa pessoa deve estar inteiramente dentro da situação para formulação da estratégia
- c) O conhecimento relevante deve estar definido antes da estratégia delineada ser implementada
- d) A organização deve estar preparada para implementar a estratégia de forma completamente coordenada.

O modelo protagonizado, para formulação de estratégias, pela escola de design deve ser preservado, apesar da aplicação restrita e da sua simplicidade, baseando-se na sua forma de correlacionar as oportunidades externas e capacidades internas [14, p. 45].

### ***Escola de Planeamento***

A escola de planeamento baseia a formulação estratégica num processo formal. Esta escola tem o seu crescimento fundamentado através da gestão da educação e sobretudo na gestão de entidades governamentais, com processos, procedimentos, análises e treinamento formalizado.

Esta escola teve o seu início relativamente ao mesmo tempo que a escola de design com o desenvolvimento do livro “Corporate Strategy” por H. Igor Ansoff publicado em 1965. O impacto maior surge na década de 70.

Atualmente esta escola tem uma leve influência na gestão estratégica das organizações [14, p. 48]. Este modelo de formulação estratégica está assente em 6 estágios [14, pp. 49-53]:

- a) Definição de objetivos: Os objetivos devem ser mensuráveis. Neste modelo os objetivos devem estar correlacionados com as estratégias, e não devem ser tratados de forma independente.
- b) Estágio de auditoria externa: Uma vez os objetivos delineados e definidos, deve ser executada uma auditoria às condições externas da organização, assim como prever futuras condições. A impossibilidade de previsão proporciona uma impossibilidade de planeamento, o que torna a definição de estratégias adequadas, também numa impossibilidade.
- c) Estágio de auditoria interna: Devem ser conhecidos os recursos, tal como competências disponíveis e estrutura financeira adequada.
- d) Estágio de avaliação estratégica: A avaliação estratégica está diretamente relacionada com a análise entre os recursos necessários para implementação da estratégia definida e os dividendos auferidos da aplicação dessa estratégia. Visa sobretudo prever qual o valor criado para a organização com a aplicação da estratégia definida.
- e) Estágio de operacionalização estratégica: Com informação dos recursos disponíveis deve-se correlaciona-los com uma hierarquia temporal de objetivos. Existem objetivos de longo, médio e curto prazo, desta forma também devem existir estratégias que estejam interligadas com esses objetivos. Paralelamente devem existir planeamentos hierárquicos orçamentais e hierarquias de sub-estratégias que converjam para as estratégias delineadas hierarquicamente superiores.



- f) Planeamento temporal de todo o processo: Não só é importante ter um planeamento da execução das estratégias, mas como também definir quando estas devem correr. Podendo assim aproveitar os objetivos e orçamentos definidos como indicadores de desempenho para as estratégias delineadas.

A escola de planeamento tem bases semelhante à escola de design, a grande diferença persiste na alta formalidade requerida pela escola de planeamento. A escola de planeamento baseia o funcionamento estratégico como uma máquina, fornecer os elementos necessários, executar as instruções de montagem e o produto final, neste caso a estratégia, irá funcionar. Uma das lacunas deste processo é o facto de quem define as estratégias (CEO) é também a pessoa que as aprova, podendo este facto ser contraproducente [14, p. 57].

### ***Escola de Posição***

A escola de posição baseia o seu modelo estratégico num processo analítico. Com a publicação do livro “Competitive Strategy”, em 1980, de Michael Porter, existiu uma estimulação extra para fomentar o desencanto dos modelos de formulação estratégica das escolas de design e planeamento [14, p. 82].

O modelo de formulação estratégica baseado na Escola de Posição não é muito diferente do modelo utilizado pelas escolas de design e planeamento, porém tem uma diferença fundamental que consiste na limitação das estratégias, onde inexistente nas escolas de design e planeamento, passa a considerar-se no modelo da escola de posição. A escola de posição defende que a posição no mercado económico é desejável, referindo que as organizações que detenham estas posições devem obter maiores lucros [14, p. 83].

Nestes modelos existe um numero limitado de estratégias básicas como diferenciação de produto e um foco no âmbito de mercado adequado e específico. O que vai contra o modelo de formulação da escola de design que refere que as estratégias devem ser únicas e específicas de cada organização [14, p. 84].

As premissas definidas por Mintzberg, et al.(1998) para o modelo de formulação da escola de posição são [14, p. 85]:

- a) As estratégias devem ser genéricas, para posições específicas e identificadas da posição de mercado.

- b) O mercado é competitivo e com uma grande vertente económica
- c) A formulação genérica está assente na escolha destas posições baseadas em cálculos analíticos.
- d) A análise tem um papel fundamental neste processo de formulação. Os analistas que fazem os cálculos disponibilizam o resultado para quem é responsável pelas opções.
- e) As estratégias inerentes a este modelo são coordenadas e executadas de acordo com a estrutura de mercado e têm como consequência uma coordenação com a estrutura organizacional.

Deste modelo de formulação sai a conhecida Matriz BCG que permite uma análise aos produtos. A matriz BCG aparece por intermédio do Boston Consulting Group que permite classificar os produtos a um nível de decisão estratégica, comparando o potencial da taxa de crescimento do mercado e a quota de mercado para esse produto.

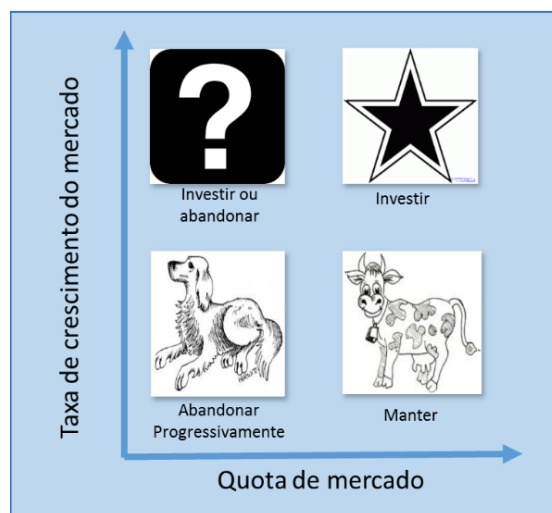


Figura 2.1: Matriz BCG

A matriz BCG classifica os produtos em quatro zonas distintas:

**Incógnitas:** Os produtos inseridos nesta classificação requerem mais capital do que aquele que geram. Este tipo de produtos pode comportar-se como “cães rafeiros” quando o capital investido serve apenas para manter a quota de mercado. O constante investimento para aumentar a quota de mercado pode torná-los em “vacas leiteiras”, mas pode nunca gerar retorno do capital investido. Produtos que se encontram nesta zona têm de ser analisados com um cuidado extra.

Cães rafeiros: Os produtos classificados nesta categoria são produtos que até podem gerar algum lucro financeiro, mas geralmente é utilizado para manter a quota de mercado. Produtos nesta categoria devem ser abandonados de forma progressiva.

Estrelas: São produtos que quase sempre geram lucros. Se os produtos, com esta classificação, forem líderes de mercado podem gerar enormes quantidades de lucros quando a taxa de crescimento diminuir assim como o investimento necessário para manter a quota de mercado, classificando-os nessa altura de “vacas leiteiras”.

Vacas leiteiras: são produtos com uma taxa de crescimento pequena, mas com uma enorme quota de mercado, geralmente geram grandes quantidades de lucro em comparação com o investimento para manter a quota de mercado.

Henderson (1979, apud Mintzberg, et al.) refere que para uma empresa ser bem sucedida deve ter um conjunto de produtos que tenham ciclos de vida diferentes e estejam presentes em segmentos de mercado distintos [14, pp. 94-95].

A matriz baseia-se em quatro pressupostos:

- a) As margens e os ganhos estão diretamente relacionados com a quota de mercado.
- b) O crescimento da quota de mercado requer investimento financeiro. O investimento requerido para manter a quota de mercado é diretamente relacional com a função da taxa de crescimento.
- c) Quotas de mercado altas requerem investimento adicional
- d) Nenhum produto específico tem crescimento infinito de mercado. Quando um produto atinge o limiar do crescimento no mercado o retorno não deve ser reinvestido no crescimento do mercado.

A escola de posição tenta, através de análises empíricas, encontrar relações entre as condições externas e as estratégias internas. Mintzberg, et al.(1998) referem que Porter através do seu livro “Competitive Advantage”, editado em 1985, ofereceu uma base para desenvolvimento das estratégias ao invés de um enquadramento estratégico pré-definido [14, p. 100].

O modelo de Porter, de desenvolvimento de estratégias, está assente na identificação analítica de 5 forças presentes na organização que tinha uma influência concorrencial [14, pp. 100-103]:

- a) Ameaça de novos concorrentes
- b) Poder de negociação dos fornecedores
- c) Poder de negociação dos clientes
- d) Ameaça de produtos substitutos
- e) Intensidade de competitividade dos concorrentes.

A diferença da necessidade de estratégias diferentes para diferentes organizações pode ser explicada pelas particularidades de cada um destes pontos. As estratégias variam com a variação de intensidade de cada um dos pontos referidos.

A escola de posição, dando ênfase aos cálculos e análises, perde algumas das faculdades que tornam a estratégia rica, evidenciando que quanto mais complexo e dinâmico for o processo de formulação mais rica será. Conclui também que a análise estratégica é adequada em ambientes estáveis e que oferecem informação suficiente para poder ser executada uma análise robusta e coerente [14, pp. 121-122].

### ***Escola de Empreendedorismo***

O método inerente à escola de empreendedorismo baseia-se na ideia que o processo de formulação estratégica é assente num processo visionário. A escola de empreendedorismo defende a intuição, sabedoria, experiência e visão como competências para formulação de estratégias.

O conceito central da escola de empreendedorismo é a visão, num âmbito que identifica a inspiração e intuição, parte da visão, como competências necessárias para formular estratégias. No entanto também referem que os economistas apresentam reservas em relação a estas ideologias, uma vez que o empreendedorismo assenta sobretudo em ideais económicos neoclássicos [14, p. 124].

Branson (1986, apud Mintzberg, et al.) apresenta algumas reflexões do empreendedor [14, p. 130]:

- a) O risco de investir num negócio que não se conhece é elevado.
- b) O envolvimento do próprio empreendedor no negócio mitiga o risco.
- c) Existem sempre outras oportunidades de negócio.
- d) É necessário ter cuidado no crescimento do negócio. Não deixar que a gestão perca contacto com os fundamentos básicos, nomeadamente no que toca aos clientes.

- e) É necessário ser objetivo no que toca à execução. Uma vez decidido onde aplicar um investimento, não se deve estar com rodeios.

Mintzberg (1973, apud Mintzberg, et al. 1998) refere quatro características que devem estar presentes na personalidade do empreendedor na formulação de estratégias [14, pp. 133-136]:

- a) No empreendedorismo a formulação de estratégias é dominada pela procura de novas oportunidades: Existe um foco nas oportunidades, fazendo que os problemas fiquem em segundo plano.
- b) Nas organizações empreendedoras o poder está centralizado nas mãos do CEO
- c) No empreendedorismo a formulação estratégica está sujeita a avanços sucessivos em relação ao desconhecido e incerteza.
- d) O crescimento é o objetivo principal numa organização empreendedora. O crescimento torna-se um dos principais indicadores de realização de objetivos.

Existem 6 premissas da escola de empreendedorismo definidas por Mintzberg, et al.(1998) [14, p. 143]:

- 1) A estratégia é formulada a partir do líder como perspectiva especificamente num período
- 2) O processo de formulação da estratégia é um processo baseado na intuição e experiência do líder, independentemente se adota a estratégia formulada por outros, e a adapta ao seu comportamento, ou formula a sua própria estratégia.
- 3) O líder promove um controle absoluto sobre a implementação da estratégia para que possa dinamicamente reformular a estratégia se necessário.
- 4) A visão estratégica é flexível, seguindo uma forma deliberada no seu todo e emergente nos detalhes.
- 5) A organização deve ser, também ela, flexível permitindo uma resposta rápida na sua estrutura organizacional consoante as estratégias adotadas.
- 6) A estratégia empreendedora tende a ser aplicada a nichos de mercado, defendendo posições de mercado dos seus concorrentes.

A escola de empreendedorismo foca aspetos críticos da formulação estratégica, como é o caso da sua natureza proactiva e o papel fundamental do líder. Esta revela, no entanto, algumas deficiências

como é a orientação comportamental de um único indivíduo na sua formulação. A forma mais simples de ultrapassar dificuldades que possam surgir é nomear outro líder estratégico. A maior parte das organizações geridas segundo estes critérios são organizações que são geridas pelos próprios proprietários [14, pp. 143-145].

### *Escola Cognitiva*

A escola cognitiva defende que a formulação de estratégias é sobretudo um processo mental. A abordagem é feita na base da análise de como a informação é percebida e processada. As estratégias são concebidas através de conceitos e esquemas bem definidos permitindo uma alusão à criatividade do indivíduo responsável pela formulação estratégica.

Uma vez que os estrategas são pessoas que se inclinam para a autoaprendizagem, estes desenvolvem processos e estruturas de conhecimentos derivados da própria experiência. A relação entre a experiência e a execução é de uma proximidade e reciprocidade alta [14, p. 150].

Os estrategas têm experiências diferentes o que torna os seus processos cognitivos distintos de estratégia para estratégia. Desta forma o estudo do perfil psicológico é útil na formulação da estratégia [14, pp. 154-155]. Para isso pode utilizar-se a ferramenta Myer-Briggs, que propõe quatro conjuntos de dimensões opostas:

Extroversão (E) <-> Introversão (I)

Sensorial (S) <-> Intuição (N)

Pensar (T) <-> Emoção (F)

Julgar (J) <-> Perceção (P)

Desta forma é possível classificar dezasseis tipos de personalidade diferentes, como por exemplo ESTJ (“extrovertido sensorial pensar julgar”) como lógico, analítico, objetivo e crítico.

A escola cognitiva defende que existe uma melhor compreensão do processo cognitivo se existir uma melhor compreensão do processo de formulação de estratégias. No entanto as implicações de tal compreensão têm mais impacto para a área da psicologia do que para a gestão estratégica [14, p. 173].

### ***Escola de Aprendizagem***

A escola de aprendizagem define a formulação estratégica como um processo emergente, ou seja as estratégias são criadas por pessoas, de forma individual ou coletiva, que aprendem com as situações assim como com a capacidade de a organização lidar com essas situações [14, p. 176].

Kiechel (1984, apud Mintzberg, et al. 1998) refere que o facto de apenas 10% das estratégias formuladas acabam por ser implementadas induziu a uma preocupação por parte dos executivos de melhorarem o processo de implementação, introduzindo critérios rigorosos no controle [14, p. 177].

O facto de James Quinn ter começado a sua investigação acreditando que as organizações formulavam estratégias como concepções integradas. Devendo para este facto usar-se métodos incrementais que permitiam saber como as estratégias tinham sido desenvolvidas e formuladas. Defendendo que seria, deste modo, possível promover estratégias dinâmicas que se alteravam e melhoravam [14, p. 180].

Para uma incrementação lógica, Mintzberg et al.(1998), através da adaptação de Quinn(1982), descrevem alguns pontos importantes [14, p. 183]:

- 1) Sistema de informação formal: Existência de um meio informativo formal
- 2) Construir uma consciência organizacional: A organização deve compreender as estratégias uma vez que estas envolvem estudos, questões, desafios e a criatividade de pessoas que se encontram fora da linha de decisão
- 3) Optar por mudanças credíveis: Pela dificuldade de comunicação dos executivos aos trabalhadores que estão inseridos nas alterações estratégicas devem optar por ações simbólicas que permitam a compreensão.
- 4) Legitimar perspectivas novas: A organização deve estar preparada para a discussão de ideias e das suas consequências
- 5) Perseguir mudanças táticas e soluções parciais: Minimizar os obstáculos inerentes a mudanças radicais.
- 6) Ampliar a política de suporte: Criar condições e mecanismos que permitam um suporte para o caso de necessidades proactivas.
- 7) Ultrapassar oposições: Persuadir indivíduos a perspetivar novos conceitos e neutralizar oposições caso seja necessário.

- 8) Criar uma estrutura flexível: Devido à impossibilidade de prever com precisão todas as ameaças e oportunidades, a estrutura deve permitir um dinamismo extra no caso de necessidade de alterações repentinas.
- 9) Desenvolver experiências e induzir compromissos: Permitir que sejam avaliados resultados e atrair propostas concretas.
- 10) Induzir objetividade e formalizar compromissos: Os objetivos e correspondentes compromissos não devem ser vagos.
- 11) Criar processos de mudança continua: Depois de uma estratégia formulada ser consensual não se deve deixar que a organização se torne inflexível.
- 12) Reconhecer a estratégia como um processo linear: A perspectiva a ter da estratégia deve capturar a iniciativa, por parte da organização, e permitir que a organização consiga lidar com eventos improváveis, assim como redirecionar recursos para novas oportunidades.

Uma estratégia deliberada baseia o seu foco no controle, permitindo que se avalie a realização das intenções estratégicas. No entanto numa estratégia emergente é permitida a aprendizagem através da capacidade de a organização executar experiências. Essas experiências têm resultados associados que possibilitam o estudo da resposta às estratégias dada pela organização [14, pp. 189-190].

Mintzberg, et al.(1998) definem 5 premissas associadas à escola de aprendizagem [14, pp. 208-209]:

- 1) A natureza complexa e imprevisível do ambiente de uma organização é muitas vezes associada ao conhecimento difuso necessário para formulação da estratégia. A formulação da estratégia deve consistir numa aprendizagem onde no limite a formulação e a implementação são executadas em conjunto.
- 2) O líder da formulação da estratégia deve aprender, sendo algumas vezes quem aprende mais. As organizações podem ter muitos potenciais estratégias.
- 3) A aprendizagem associada a formulação da estratégia deve estimular o pensamento através do comportamento. As iniciativas da formulação estratégica devem ser feitas por quem tem os recursos e a capacidade da



aprendizagem. As iniciativas experimentais bem-sucedidas devem convergir para uma padronização de ações na criação de estratégias emergentes.

- 4) A função principal do líder não é conceber estratégias deliberadas mas gerir o processo de aprendizagem estratégica.
- 5) As estratégias devem aparecer primeiro como padrões induzidos pelas experiências, e só depois como planos estratégicos e, por último, como perspectivas de orientação comportamental.

A escola de aprendizagem tem um papel importante na criação de conhecimento. Mintzberg, et al(1998) advertem para o fato de os gestores de níveis intermédios terem um papel fundamental na função que converte conhecimento tácito em conhecimento explícito [14, p. 210].

A organização deve aprender coletivamente no caso de necessidade de formulação de uma nova estratégia, e quanto mais complexo for o ambiente inerente à organização mais crucial se torna esta aprendizagem. A escola de aprendizagem trouxe uma nova realidade à formulação de estratégias por parte das organizações, instigando a evolução a partir de experiências e o desenvolvimento a partir da complexidade e dinâmica do ambiente [14, pp. 228-230].

### ***Escola de Poder***

A escola do poder defende que a formulação estratégica é baseada num processo de negociação. A escola de poder foca o uso de poder, influência e negociação para formulação de estratégias que se orientam por interesses particulares [14, p. 234].

O facto de as organizações estarem rodeadas de relações onde o poder e a influência tem um papel fundamental na sua orientação. Existindo dois tipos de poder em relação à dimensão: micro poder que se encontra incorporado na organização e que lida sobretudo com políticas e o macro poder que se define com o uso do poder organizativo em relação ao ambiente exterior [14, pp. 234-236].

Mintzberg (1984, apud Mintzberg, et al. 1998) refere alguns tópicos inerentes aos jogos políticos internos às organizações, ficam alguns exemplos [14, p. 237]:

- 1) Patrocinador: serve para construir uma base de poder, consiste no aproximar de indivíduos que detêm mais poder, troca lealdade por poder.

- 2) Alianças: Negociação entre indivíduos do mesmo nível hierárquico para se protegerem e avançarem dentro da organização.
- 3) Construção de império: O mesmo que a aliança, mas com a diferença que é feito com níveis hierárquicos inferiores.
- 4) Experiência: O uso de experiência para construir poder. A exploração do conhecimento e de competências fundamentando a sua unicidade e importância.
- 5) Candidatos estratégicos: Tem o intuito de executar alterações na organização. Essas alterações devem favorecer em algum aspeto o indivíduo.
- 6) Jovens turcos: Consiste nas alterações organizacionais por parte de um pequeno grupo para que consigam alterar a orientação das estratégias básicas de uma empresa e com isto remover a liderança alterando a sua cultura.

As estratégias não são apenas planos de ações a serem executadas, mas também evidências de alteração de relações baseadas em poder. Quanto mais importante for a estratégia a ser formulada e quanto mais for a organização descentralizada, maior é a probabilidade do uso de manobras políticas. As organizações que formulam estratégias por este método podem ser induzidas em custos elevados que poderiam ser utilizados para satisfação dos clientes. A negociação mal sucedida pode levar à criação de obstáculos e mesmo a paralisação do negócio [14, p. 241].

No entanto que este método de formulação de estratégias pode ter mesmo um papel funcional na organização, podendo mesmo fazer parte duma evolução por meio de seleção do mais forte e bem relacionado. Muitas vezes estratégias políticas como a “turcos jovens” permite que sejam corrigidos comportamentos irresponsáveis e ineficazes [14, pp. 242-244].

Por outro lado, em termos externos às organizações, o processo negocial e político permite as organizações uma adaptação das organizações ao meio ambiente, ao invés de um processo baseado na reação. A organização deixa de ser o único condutor no caminho para o crescimento [14, p. 248].

Estão identificadas três estratégias básicas que a organização tem ao seu dispor [14, p. 249]:

- 1) A organização pode tratar de um problema de cada vez: Cada problema é tratado e só depois se passa ao seguinte.

- 2) A organização pode esconder ou divulgar informação: A informação é um ativo importante numa organização, saber que informação deve ser escondida ou que deve ser divulgada pode ser um importante marco estratégico
- 3) A organização pode colocar grupos contra outros grupos: A organização pode optar por estratégias que têm tanto grupos de suporte como grupos contra.

As premissas da escola de poder estão identificadas como [14, p. 260]:

- 1) A formulação estratégica é baseada em poder e políticas, tanto no comportamento interno à organização, como na relação desta com o ambiente envolvente.
- 2) As estratégias resultantes deste processo tendem a ser emergentes e mais baseadas na posição do que na perspetiva.
- 3) O micro poder visa uma estratégia baseada em negociação, persuasão ou confronto direto como um jogo de interesses, onde as entidades dominantes estão constantemente a ser mudadas.
- 4) O macro poder visa uma estratégia que permite à organização promover-se através do controlo e cooperação com outras entidades.

As estratégias formuladas por intermédio das ideologias da escola de poder são importantes, na medida que formalizam o papel de forças integradas como é o caso de liderança e cultura. No entanto podem perder o discernimento em relação aos objetivos, potenciando desperdícios e custos elevados derivados por conflitos [14, pp. 260-261].

### ***Escola Cultural***

A escola cultural é uma imagem invertida, como num espelho, da escola de poder, defendendo que a formulação estratégica faz parte de um processo coletivo. A escola cultural é induzida por um conjunto de indivíduos colocados numa organização, onde os primeiros têm interesses próprios e a segunda proporciona um interesse coletivo. Existe dois interesses privilegiados, o primeiro diz respeito à promoção da mudança estratégica e o segundo à utilização da cultura como influência para a manutenção da estabilidade estratégica [14, p. 264].

A cultura gera unicidade na forma como as coisas são feitas. Culturas diferentes protagonizam formas diferentes e únicas de como os processos são executados, pelo que o desempenho e os

resultados podem ser diferentes. Sendo que as pessoas têm comportamentos diferentes e que a cultura induz uma subjetividade no processo de interpretação [14, p. 264].

A definição de cultura é vastamente debatida, mas para Mintzberg, et al (1998), a cultura é baseada nas diferentes interpretações associadas à perspetiva do mundo que conhecemos. Essas interpretações são, no entanto, partilhadas através de um processo social., tornando as ações individuais parte de um processo coletivo [14, p. 266].

Algumas premissas da escola cultural podem ser descritas da seguinte forma [14, pp. 267-268]:

- 1) A formulação estratégica é um processo social consistindo na interação entre os seus membros e baseada nas suas crenças e interpretações.
- 2) Um individuo está suscetível de adquirir crenças através de um processo cultural ou de socialização.
- 3) Os membros de uma organização têm traços culturais gerais conforme a sua cultura, mas onde as origens desses traços podem ser de difícil explicação.
- 4) A estratégia é definida através da perspetiva induzida pelas intenções coletivas e pelas capacidades organizativas, com intuito de proteger a organização e induzir vantagens competitivas.
- 5) A cultura não encoraja por si só a mudança estratégica, mas pode promover alterações significativas na perspetiva estratégica.

A cultura é induzida pelo partilhar de conhecimento através de atividades sociais, como o conversar, celebrar e conviver, assim como a execução de tarefas em conjunto [14, pp. 276-277].

Barney (1991, apud Mintzberg, et al. 1998) estipula quatro critérios para definir que recursos têm importância estratégica para uma organização [14, p. 278]:

- 1) Valor: Um recurso deve ter valor para poder ser considerado um recurso estratégico. Deve poder melhorar a eficiência e eficácia da organização
- 2) Raridade: Um recurso para ser considerado estratégico não deve ser possuído pelos seus competidores. Quanto mais raro for um recurso maior será a vantagem estratégica associada à sua utilização.
- 3) Inimitável: Um recurso não deve ser imitável facilmente. Permitindo que a vantagem estratégica continue a ser detida por quem detém o recurso.

- 4) Insubstituível: Um recurso não deve poder ser substituído por outro que permita obter o mesmo resultado.

Estes critérios apresentados focam-se sobretudo na vantagem estratégica, através dos recursos, como um ponto crítico para a vantagem competitiva. Isto é, enquanto existirem recursos estratégicos, com valor e únicos numa organização, estes podem ser utilizados para adquirir vantagem sobre os concorrentes.

Neste sentido a cultura pode ser um recurso estratégico valioso, uma vez que a diversidade de indivíduos e crenças pode ter um impacto estratégico significativo nos processos organizacionais, assim como nos produtos e serviços criados.

### ***Escola de Ambiente***

A escola de ambiente defende a formulação estratégica como um processo reativo. Esta escola veio enaltecer a formulação de estratégias através do ambiente em que a organização se encontra inserida. Fomentou os debates entre as ideologias do que os gestores conseguem ou não fazer, defendendo que as ações dos gestores estão limitadas ao ambiente que os rodeia, seja de uma forma concorrencial ou mesmo económica [14, pp. 286-287].

O crescimento da escola ambiente deveu-se, numa fase inicial, à teoria de contingente, que descrevia as relações entre dimensões do ambiente e as características da organização. Certas particularidades do ambiente externo implicava a organização seguir caminhos específicos no mercado [14, p. 288].

Existem quatro premissas referentes à escola de ambiente [14, p. 288]:

- 1) O ambiente é apresentado à organização como um conjunto de forças e é um fator crítico na formulação estratégica.
- 2) A organização deve reagir a estas forças, se não o fizer pode ser excluída.
- 3) A liderança passa a ser um elemento passivo na adaptação apropriada da organização ao ambiente.
- 4) As organizações tendem a agrupar-se em focos distintos, onde ficam até os recursos serem escassos e as condições demasiado difíceis para sobreviver.

Existem quatro tópicos inerentes à perspectiva de contingente [14, pp. 289-290]:

- 1) Estabilidade. O ambiente de uma organização pode ir de estável a dinâmico, onde os clientes procuram os mesmos produtos ou serviços até aqueles que procuram serviços e produtos inovadores.
- 2) Complexidade. O ambiente de uma organização pode ir de simples a complexo. Isto é, pode fornecer produtos ou serviços que necessitem conhecimento simples ou fornecer produtos ou serviços que necessitem de conhecimento qualificado ou avançado.
- 3) Diversidade de mercado. Os mercados atingidos por uma organização podem ser integrados ou diversificados, isto é, podem ser de um simples produto ou serviço ou podem englobar um conjunto extenso de produtos ou serviços.
- 4) Hostilidade. O ambiente inerente a uma organização pode ser desde pacífico a hostil, isto é, uma organização que detém um produto ou serviço onde se dá ao luxo de escolher os seus clientes até uma organização que tem de negociar ferozmente com os clientes para obter a sua aprovação.

Santos (2008) refere que “a Escola Ambiental integra as teorias, que encaram a estratégia como mera resposta organizacional, com vista a assegurar a adequação da organização ao seu meio ambiente”. A Escola Ambiental defende o meio ambiente como um ator, estabelecendo um conjunto de regras à organização, cabendo a esta de uma forma passiva reagir. [16, p. 366].

### ***Escola de Configuração***

A Escola De Configuração defende a formulação estratégica como um processo de transformação, providenciando uma forma de integração das ideologias das outras escolas.

Esta escola enquadra-se em duas perspetivas principais, uma descreve a organização e o seu contexto, como configurações, a outra descreve o processo de formulação de estratégias, como transformação. As perspetivas não são independentes, uma vez que a formulação de estratégias está diretamente ligada com o contexto em que a organização se insere [14, p. 302].

Estão definidas seis premissas da Escola De Configuração [14, p. 305]:

- 1) Na maior parte do tempo, uma organização pode ser descrita a partir de características estáveis. Por períodos de tempo distintos, a organização tem características próprias assignadas a um contexto específico.

- 2) Os períodos de estabilidade podem ser interrompidos por processos de transformação.
- 3) Os diferentes períodos de transformação e estados de configuração podem ser induzidos em sequências padrão, muitas vezes de acordo com os diferentes ciclos de vida da organização.
- 4) A sustentabilidade da organização está diretamente ligada com o seu processo de formulação estratégica. Deve estar definida para uma adaptação organizacional através da transformação, sem destruir a organização.
- 5) As ideologias das outras escolas devem estar associadas ao processo de formulação estratégica, mas de uma forma coerente e consistente, em que o seu uso seja feito de forma adequada, quer no contexto quer no tempo.
- 6) As estratégias resultantes devem ter a forma de planos, posições ou perspectivas adequadas ao contexto e situação.

O verdadeiro desafio está em conseguir sustentar o período de estabilidade o maior período de tempo possível, mas sem incorrer no erro de observar os fatores indicativos da necessidade de mudança, permitindo à organização uma adaptação ao ambiente através de uma nova configuração [16, p. 370].

### **2.1.5 Níveis de Estratégia**

#### ***Estratégia Global da Organização***

A estratégia global ou corporativa como a estratégia que descreve a direção que a organização deve seguir, no seu todo. Esta estratégia engloba um planeamento feito de forma geral e transversal a toda a organização, permitindo definir a gestão dos seus produtos e serviços. Deve assentar e 3 categorias principais: crescimento, estabilidade e redução de custos [17]. A estratégia corporativa é fundamentada pelo facto de a empresa necessitar ganhar vantagem competitiva operando em vários mercados e negócios simultaneamente [18].

A estratégia corporativa faz parte do processo final da formulação da estratégia. No entanto as estratégias de negócio e as estratégias funcionais devem ser determinadas a partir das estratégias corporativas [9, p. 285].

### ***Estratégia de Negócio***

A estratégia de negócio deve ser feita a nível de unidades de negócio ou produto, tendo em consideração o seu segmento de mercado ou indústria, e que deve permitir melhorar a sua posição competitiva [17, p. 115]. Baseia-se em ações executadas com o objetivo de ganhar vantagem competitiva num mercado ou setor. As duas estratégias mais importantes, segundo estes autores, a estratégia de negócio são a liderança de custo e a diferenciação de produto [18, p. 102].

Os gestores para criar um modelo de negócio bem-sucedido têm de criar estratégias de negócio que façam sobressair e aproveitem as vantagens competitivas inerentes à organização. Estas estratégias devem estar relacionadas com as necessidades dos consumidores e a sua satisfação, tal como as diversas competências existentes na organização [9, pp. 145-147].

A estratégia de liderança de custo consiste em a organização ganhar vantagem competitiva através da redução dos seus custos, de forma a que estes sejam inferiores aos seus concorrentes [18, p. 102]. Duas vantagens na aplicação de estratégias de liderança de custo: A primeira assenta no facto de custos menores podem trazer um aumento nos lucros e a segunda, porque permite uma vantagem competitiva na possibilidade de uma redução dos preços para o consumidor [9, p. 245].

A estratégia de diferenciação de produto quando uma organização ganha vantagem competitiva através de diferenças criadas nos seus produtos por meio de alterações de características objetivas e específicas. Defendem também que a diferenciação é uma questão perspectiva dos consumidores, isto é, deve existir um aumento de valor percebido pelos mesmos [18, p. 131].

A diferenciação deve ser orientada à necessidade dos consumidores. A organização ganha competitividade quando cria produtos que vão de encontro às necessidades dos consumidores de uma forma melhor que os seus concorrentes [9, p. 145].

As estratégias formuladas a nível do negócio devem permitir à organização criar e gerir uma vantagem competitiva que permita a sobrevivência e mesmo o crescimento da organização. As estratégias a este nível têm um papel fundamental nos objetivos da organização criando uma ponte entre as estratégias corporativas e as estratégias funcionais.

### ***Estratégia Funcional***

Esta estratégia deve permitir o alcance, por parte da organização, dos objetivos definidos na estratégia global e da estratégia de negócio. Esta estratégia deve estar aliada às competências



funcionais e permitir que se alcance uma vantagem funcional competitiva, mesmo que esta seja na maximização da produção, quer por melhoria dos processos ou através de novas tecnologias [17, p. 165].

As estratégias funcionais têm como alvo principal o melhoramento e otimização da operacionalização da organização. Desta forma está associado a esta estratégia a obtenção de vantagens competitivas através da eficiência operacional, a inovação e qualidade do produto e satisfação do consumidor [9, p. 107].

A estratégia funcional está associada a necessidade de adquirir competências e características inerentes aos recursos humanos. A proximidade deste nível estratégico com os níveis hierárquicos inferiores da organização providencia uma posição de vantagem para conhecer as necessidades da organização no que toca a este ponto [9, p. 120].

### **2.1.6 Princípios Estratégicos**

As batalhas existentes na arena dos negócios são, de alguma forma, idênticas às batalhas da arena militar. Por isso a estratégia é fundamental nos negócios, quer seja para a defesa de uma posição quer seja para uma entrada em novos mercados [16, p. 126].

#### ***Ataque***

Sun Tzu, um general, estratega e filósofo chinês, viveu de 544 a.c a 496 a.c. e que escreveu a obra “A Arte da Guerra”, afirmou “Se não for vantajoso, não te movas. Se não houver certeza do êxito, não utilizes as tuas tropas, se não estiveres em perigo, não combatas”.

Tal como na ciência militar, na gestão as guerras devem ser evitadas. Os recursos utilizados numa guerra entre concorrentes podem mostrar-se cruciais para a sobrevivência da organização, isto significa que a guerra entre concorrentes pode ser fatal para as organizações [16, p. 127].

O ideal é ganhar uma guerra sem combater. A organização não deve destruir postos de trabalho em favor de uma guerra ou mesmo destruir a sua imagem. A guerra deve apenas ser travada se daí resultar uma vantagem significativa.

Algumas regras que devem ser tomadas em consideração no princípio do ataque [16, p. 128]:

- 1) Antes de fazer qualquer movimento devem ser tomadas ponderações sobre os eventuais resultados que daí possam surgir.
- 2) Devem ser avaliadas as oportunidades quer na dimensão, quer no tempo. Devem ser criadas condições de certeza da vitória.
- 3) Os segredos das estratégias a executar devem ser impenetráveis, ou seja, considerar-se de muito valor o provérbio popular “No segredo é que está a alma do negócio.”.
- 4) Devem ser simuladas estratégias de forma a confundir e a enganar o adversário. A simulação pode levar que o adversário execute estratégias erradas e, por conseguinte, fatais.
- 5) A análise dos concorrentes é crucial, mas a análise interna é de extrema importância. Conhece os clientes, concorrentes e meio envolvente e a probabilidade de vitória aumentará consideravelmente.
- 6) Devem ser atacados os segmentos de mercado que o inimigo se veja incapaz de defender ou pelo menos que o seu tempo de resposta seja diminuto.
- 7) A uma guerra de concorrentes, deve salientar-se a necessidade de motivação dos trabalhadores através de recompensas.

### ***Defesa***

O princípio de defesa é fundamentado pela necessidade constante de estar preparado para um ataque por parte dos concorrentes. Desta forma não se deve supor que os concorrentes não atacam a qualquer altura as posições ou quotas de mercado pertencentes a outras organizações [16, p. 131].

- 1) Uma organização pode ser derrotada, mesmo que titular de estratégias superiores. Isto pode acontecer caso a organização não disponha de recursos suficientes para assegurar a execução da sua estratégia.
- 2) A vitória numa guerra concorrencial pode estar associada a:
  - a. Ao grau de conhecimento que se tem, quer dos concorrentes, quer internamente. Com esse conhecimento pode dar-se a oportunidade de enganar ou induzir os concorrentes em erro.

- b. Da aptidão da organização prever os movimentos estratégicos e táticos dos concorrentes.
- c. Da sua capacidade para concentrar e focar os seus recursos, de forma a aproveitar os pontos fracos dos concorrentes.

### ***Concentração e foco***

Este é o princípio mais importante da estratégia, uma vez que o conceito de estratégia é fundamentado no provérbio “a união faz a força” [16, p. 132]. Sun Tzu reconhece que nem sempre que a força de um exército está no número das suas tropas ou recursos. No entanto foca a sua força no conhecimento do inimigo e suas estratégias.

A concentração e foco nas funções e áreas operacionais chave da organização, e por conseguintes determinantes para o sucesso da organização [16, p. 132].

Vasconcelos e Sá (1996, apud Santos, 2008) defende que a organização deve concentrar-se e focar-se nas atividades críticas, onde a excelência é um requisito fundamental. Evitando assim a dispersão da afetação dos recursos organizacionais por todas as áreas [16, p. 133].

### ***Informação***

O princípio da informação pretende focar a importância do conhecimento sobre o inimigo e que a sua capacidade se baseia na análise de informação sobre o próprio exército. A informação utilizada deve estar associada à excelência da qualidade e exatidão, para que a análise e planeamento sejam feitas nas melhores condições [16, p. 134].

- 1) As vantagens competitivas, associadas à posse antecipada de informação, que permita uma ultrapassagem significativa aos seus concorrentes fornecendo bens ou serviços de valor superior. Esta informação deve permitir.
- 2) Conhecer a concorrência, desde os seus objetivos, pontos fortes, pontos fracos, clientes, oportunidades e ameaças, assim como recursos, atividades e nível de inovação.
- 3) Atuar com base nessa informação
- 4) Enganar ou confundir a concorrência, através da disseminação de informação falsa sobre as suas intenções e estratégias.

### ***Análise e Planeamento***

A gestão deve analisar exaustivamente as variáveis-chaves ou críticas para o negócio, compreendendo as medições, estimativas, cálculos e avaliação de oportunidades [16, p. 136]. O movimento estratégico da organização deve estar devidamente estudado:

- 1) Ponderar criteriosamente e exaustivamente, as vantagens e desvantagens associadas às várias alternativas inerentes aos movimentos estratégicos.
- 2) Ter como resultado da cuidadosa análise, os pontos fortes e pontos fracos dos concorrentes.
- 3) Ter em consideração que o segredo e confidencialidade são pontos cruciais.

### ***Ação***

As vantagens competitivas baseiam-se na execução de ações previamente definidas, sejam elas ofensivas ou defensivas. As ações a executar ou executadas devem beneficiar de um mérito próprio, uma vez que a análise e planeamento devem ser acompanhados das ações inerentes para que a estratégia tenha sucesso [16, p. 139].

O sucesso das ações depende de sobretudo da rapidez de execução, surpresa e simplicidade. A inovação pode ter um papel importante no sucesso da estratégia, essa inovação está associada a gestores com pouca aversão ao risco e que conseguem potenciar o desempenho das suas organizações.

### ***Segredo/Surpresa***

A eficácia das ações associadas ao elemento confidencialidade ou surpresa pode ser potencializada ao seu máximo. O efeito surpresa depende da capacidade de organização manter o secretismo das suas estratégias e ações competitivas. Clausewitz (2003, apud Santos, 2008) refere que a surpresa “é o princípio mais eficaz para obter a vitória” referindo que esta pode ser mesmo mais importante que na estratégia do que na tática [16, p. 142].

O sigilo não implica apenas o esconder da intenção, dos inimigos, mas também pela capacidade dos líderes manterem os seus subordinados na sua ignorância. Isto significa partir em partes a estratégia e mostrar apenas as partes aos intervenientes numa base de *need-to-know* [16, p. 242].

Os benefícios da ocultação são ainda maiores se o conhecimento sobre os concorrentes for vasto, ou mesmo absoluto. A divisão dos recursos do concorrente para proteção dos vários flancos pode deixar este suscetível ao ataque através de estratégias adequadas.

### ***Liderança***

O princípio da liderança projeta que a informação ou estratégia pode não ser suficiente para uma vitória. Os líderes devem estar cientes da operacionalidade dos planos, liderando eficazmente o conjunto de intervenientes nas operações [16, p. 145].

Nos atuais ambientes empresariais denota-se uma preocupação constante em fundamentar uma cultura organizacional que vá de encontro a um objetivo comum a toda a organização. A liderança permite que a gestão seja orientada e planeada de acordo com estratégias específicas permitindo que toda a organização possa estar coordenada e direcionada para esse objetivo comum.

É do senso comum e bastante natural que o significado da presença de liderança não pode ser deixado ao acaso ou subestimada em atividades de grupo. A natureza humana não é orientada à organização e planeamento das atividades de grupo caso não exista liderança, isto é, na ausência de liderança as atividades em grupo tendem a ser desorganizadas, confusas e mesmo caóticas.

Um líder dinâmico e competente pode ser comparado a um dínamo que gera eletricidade, carregando e ativando todo um grupo de tal forma que os objetivos poderão ser alcançados sem grande dificuldade. O sucesso de uma organização está geralmente dependente de uma boa liderança. Uma liderança dinâmica tende a aumentar o nível de autoestima dos subordinados e estimula-os para concretizarem o conjunto de objetivos dentro de prazos definidos.

Uma organização sem liderança é como um exército sem comandantes ou generais. A força laboral necessita da liderança de indivíduos experientes que possam providenciar orientações para que todos os colaboradores sigam numa única direção. Os líderes são de um valor extremo quando analisados quanto à formulação e comunicação de novas estratégias, assim como na indução de motivação com o objetivo de aumentar a dedicação dos colaboradores.

Uma boa liderança tem um papel fundamental em orientar o grupo para elevar a sua performance a um nível superior. A força ou apenas a autoridade nem sempre alcança os resultados desejados. O complemento da liderança com a autoridade, influenciando e inspirando, pode acrescentar valor

ao trabalho quer de equipa quer individual. O papel da liderança é notório a todos os níveis hierárquicos da organização em termos de gestão porque a ausência de liderança pode induzir um ambiente instável e frágil.

Nenhuma organização pode providenciar todos os tipos de relações pessoais, nem de colmatar todas as necessidades dos seus colaboradores. As relações informais podem ser mais eficazes no controle do comportamento dos seus colaboradores para os direccionar para o sucesso. Uma liderança adequada aumenta o entendimento entre os vários níveis hierárquicos para que se alcance mais facilmente os objetivos globais da organização.

### ***Motivação***

A motivação de pessoas tem uma importância crucial na praticabilidade da liderança na indústria, comércio ou serviços públicos.

Uma pessoa esteja motivada quando ao ato de executar uma tarefa está inerente à necessidade pessoal, ou seja, se sinta incentivada a fazê-lo. Um motivo não é o mesmo que um incentivo [16, p. 147].

A motivação é um sentimento interno que deve ser compreendido pelo gestor que está em contacto com os subordinados. As necessidades e desejos estão diretamente relacionados com o sentimento inerente ao executar. Estas necessidades e desejos devem ser analisados e compreendidos para que se possa fazer um plano de motivação inerente a um grupo ou equipa. Como as necessidades e desejos estão em constante mutação este plano deve ser redefinido constantemente num processo contínuo.

### **2.1.7 Formulação e Implementação de Estratégias**

#### ***Fases da Gestão Estratégica***

A gestão estratégica pode ser definida como um conjunto de decisões e ações que a longo prazo determinam o desempenho de uma organização [17, p. 2]. O estudo da gestão estratégica revela-se importante em todas as vertentes da organização, desde os recursos humanos, passando pela tecnologia, até aos clientes e ambientes sociais. Neste sentido todas as oportunidades e ameaças devem ser tomadas em consideração, monitorizando-as e avaliando-as.

Existem 4 fases importantes da gestão estratégica [17, p. 3]:

- 1) Fase 1: Planeamento financeiro básico. Ainda que exista um planeamento financeiro básico, este tem uma importância crucial. Geralmente os gestores elaboram um planeamento financeiro tendo em conta a informação inerente à empresa, quer esta seja informação interna, quer esta seja informação relativa ao ambiente externo.
- 2) Fase 2: Planeamento previsional. O planeamento previsional deve permitir aos gestores obter indicadores de o que se espera dos resultados que um determinado projeto possa providenciar. Os orçamentos previsionais permitem identificar problemas numa fase inicial dos projetos, permitindo avaliar a viabilidade da aplicação estratégica.
- 3) Fase 3: Planeamento estratégico. A gestão de topo deve ter controlo do processo de planeamento estratégico. Existe nesta fase uma necessidade de rever as fases anteriores e mitigar a ineficiência dos planos previsionais. Nesta fase os planos são criados por pessoal específico e com competências para tal.
- 4) Fase 4: Gestão Estratégica. Nesta fase todo o planeamento estratégico deve percorrer a organização até aos níveis de gestão mais baixos, para que estes possam criticar, dar ideias e se comprometam com os objetivos estratégicos da organização. Neste sentido são desenvolvidos planos estratégicos orientados à sua implementação, avaliação e controlo. Estes planos estratégicos devem conter cenários prováveis, assim como planos contingenciais.

### ***Benefícios da Gestão Estratégica***

Alguns dos benefícios importantes da gestão estratégica, sendo que as organizações que delineiam planos estratégicos e respetivos indicadores de desempenho têm uma vantagem que se verifica no desempenho, em relação às organizações que não o fazem. Um estudo feito a 50 organizações, em vários países e a várias indústrias, que permitiu identificar os três mais importantes benefícios da gestão estratégica [17, p. 4]:

- 1) Uma visão estratégica mais profunda e clara para a organização
- 2) Um foco melhorado no que realmente é importante estrategicamente para a organização
- 3) Um melhor entendimento do ambiente dinâmico que envolve a organização

São benefícios que permitem à organização uma postura adequada em relação às oportunidades e ameaças de que as organizações são alvos, num ambiente económico e tecnológico em constante mudança. Estes três benefícios permitem à organização ter um melhor entendimento do caminho a seguir para concretizar os seus objetivos, assim como ultrapassar obstáculos, ou mesmo transformar obstáculos em oportunidades.

### ***Modelo Básico de Gestão Estratégica***

Wheelen e Hunger (2002:9) defendem que um modelo básico de gestão estratégica consiste em quatro elementos:

- 1) Análise ambiental
- 2) Formulação estratégica
- 3) Implementação estratégica
- 4) Avaliação e controlo

#### **Análise ambiental**

A análise ambiental consiste em reunir a informação adequada dos ambientes inerentes à organização, quer seja o ambiente interno ou externo. Esta informação deve ser alvo de uma análise cuidadosa e que permita identificar fatores estratégicos, ou seja fatores que possam determinar o futuro da organização [17, p. 9].

As oportunidades e ameaças, pertencentes ao ambiente externo da organização, e juntamente com as forças e fraquezas, pertencentes ao ambiente interno da organização, ao serem analisadas no seu conjunto, permitem a identificação de pontos estratégicos a serem executados ou a serem corrigidos.



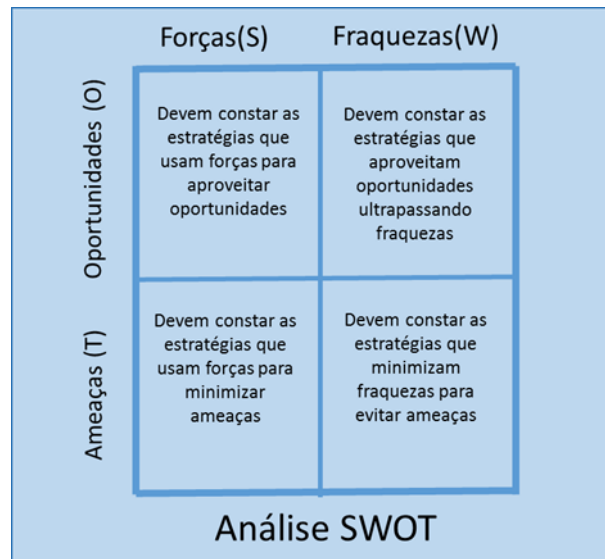


Figura 2.2: Análise SWOT (adaptado Wheelen e Hunger, 2002:115)

A análise SWOT (Strengths, Weakness, Opportunity and Threats) como um método para identificar as competências de uma organização e também um método para identificar as oportunidades inerentes ao ambiente envolvente. Defendem que esta análise provou ser uma das técnicas analíticas mais vantajosas. De qualquer forma existem alguns problemas inerentes a esta técnica como é o caso de gerar longas listas, não existe uma forma de definir prioridades e pode não existir uma relação com análise de dados ou informação [17, p. 109]. A análise SWOT deve fazer parte integrante do processo inicial do planeamento e definição de estratégias [19, p. 221].

## Formulação estratégica

A formulação estratégica é a criação de planos a longo prazo que permitam à organização uma gestão eficiente das oportunidades e ameaças consoante os seus pontos fortes e as suas fraquezas, criando objetivos e desenvolvendo estratégias [17, p. 10].

Se uma estratégia induz problemas na estratégia corrente de uma organização então devem ser estudadas as opções estratégicas mais adequadas que a organização possa ter. As opções estratégicas devem permitir um aproveitamento das oportunidades expostas pelo ambiente externo para o qual o seu ambiente interno apresente forças adequadas [20, pp. 387-388].

### Implementação estratégica

O processo de implementação estratégica como o processo que permite a colocação em ação das estratégias definidas, considerando procedimentos, orçamentos e programas desenvolvidos para o efeito. Este processo pode envolver alterações a nível da cultura ou estrutura organizacional, assim como no sistema de gestão da organização [17, p. 15]. Se a estratégia a ser implementada exigir um afastamento da estratégia atual, então deve-se induzir uma alteração no contexto interno da organização. Por sua vez a implementação estratégica deve existir após uma formulação estratégica coerente, mas a implementação pode trazer alterações à estratégia inicialmente prevista [20, pp. 16-17].

### Avaliação e Controlo

O processo de controlo e avaliação como um processo onde as atividades organizacionais, assim como o seu desempenho, são sujeitos a processos de verificação que permitam identificar o nível de sucesso alcançado com o que é desejado. A avaliação e controle permite que a organização identifique problemas e que possa criar soluções em tempo útil [17, p. 16].

Os gestores que falharem no controlo estratégico podem ganhar algumas batalhas, mas certamente não ganharão a guerra. As estratégias estão orientadas à estratégia corporativa, o que significa se as estratégias de nível inferior falharem, a estratégia corporativa também irá falhar. Os indicadores de controlo estratégico permitem que se obtenha informação sobre o estado das estratégias em cada um dos níveis propagando-se para o nível de topo [19, p. 539].

Um controlo estratégico formal ajuda a manter os planos no bom caminho. O controlo estratégico permite identificar problemas e, por conseguinte, corrigir problemas em tempo útil [19, p. 215].

### ***Gestão Estratégica em Ambientes de Incerteza***

A mudança é um dos maiores desafios que os gestores podem enfrentar. A mudança de fatores do ambiente externo leva à necessidade dos gestores reconhecerem e compreenderem como a mudança afeta internamente a organização. A mudança é geralmente acompanhada de algum nível de incerteza [20, p. 271].

O grau de incerteza está associado à conjugação do dinamismo com a complexidade do ambiente, podendo causar falta de informação tendo impacto no desempenho organizacional. O grau de

incerteza é tanto maior quanto maior for o dinamismo e complexidade do meio envolvente [16, p. 22].

A necessidade de mudança pode estar associada a fatores externos, tais como uma vantagem competitiva adquirida por um concorrente, ou ainda a fatores micro e macroeconómicos, desfavoráveis ou favoráveis, que induzam ou permitam uma mudança na estratégia da organização.

A vantagem competitiva é um ponto fulcral no sucesso de uma estratégia. Existem fatores que podem levar a organização a perder as suas vantagens competitivas, nomeadamente a entrada no mercado de concorrentes fortes com novos processos ou novas tecnologias [20, p. 274].

Os modelos estratégicos adotados devem permitir à organização alterar o caminho a seguir com base na necessidade mediante os objetivos. Com isto a organização procura estar preparada para dar uma resposta imediata a quaisquer mudanças que devam de ser feitas, de forma a otimizar o seu desempenho.

O lançamento de um produto inovador pode trazer consigo o inconveniente de não ser possível prever de forma satisfatória a procura por parte dos consumidores [20, p. 280].

Existem vários riscos inerentes a um contexto de incerteza [6, p. 510]:

- 1) Os investimentos efetuados têm inerente uma procura esperada, caso essa procura não seja alcançada pode comprometer seriamente os resultados da organização.
- 2) Se existir uma procura muito maior à esperada e a organização não estiver preparada para aproveitar a oportunidade pode perder quota de mercado e lucros para a concorrência.
- 3) Se uma organização não avaliar diferentes cenários associados ao ambiente envolvente corre riscos de algum imprevisto ter impacto no seu desempenho.
- 4) A avaliação de cenários feita defeituosamente, no caso de evoluções no mercado, pode incorrer em tempos de resposta demasiado longos.

A incerteza é gerada a partir da crença que não é possível fazer previsões precisas, o que pode acontecer por falta de informação relevante induzindo uma incapacidade de antecipar

consequências. Raposo (2013) defende que “Por vezes, a incerteza é tratada como algo que pode ser eliminado e não como algo que deve ser estimado” [21, p. 121].

Deve-se identificar antecipadamente problemas recorrendo a técnicas previsionais, e preparando a organização para eventualidades futuras. Controlar, influenciar ou atuar sobre as fontes de incerteza podem permitir mitigar os impactos causados, e o aumento de flexibilidade e competitividade estrutural podem reduzir a exposição à incerteza [6, p. 511].

A previsibilidade não é o inverso de incerteza, mas sim o grau da “certeza probabilística com que se consegue antever determinados acontecimentos”. Sendo que existe uma relação inversa entre a previsibilidade e a incerteza. Quanto mais dinâmico e complexo for o meio envolvente maior dificuldade a organização a para prever acontecimentos [16, p. 23]. A organização deve procurar acompanhar o dinamismo do meio envolvente, recolhendo informação e procurando adaptar-se para que possa aproveitar oportunidades ou mitigar ameaças.

### **2.1.8 Alianças Estratégicas**

As alianças estratégicas segundo Barney e Hesterly(2007) estão incluídas nas estratégias corporativas. Este tipo de estratégias visa criar sinergias entre parceiros comerciais para que possam otimizar o desempenho dos seus negócios. Desta forma considera-se que tem uma importância acrescida numa atualidade em que se enfrenta uma globalização dos negócios, como estes estão inseridos em mercados extremamente dinâmicos [18].

Aliança estratégica pode ser definida como a cooperação entre duas ou mais empresas podendo ser no desenvolvimento, produção ou na venda de bens e serviços. As alianças estratégicas criam valor aproveitando oportunidade e anulando ameaças com que as organizações são enfrentadas. Melhorar as operações, criar um ambiente competitivo favorável e facilitar a entrada de uma organização de novos mercados são exemplos de categorias enquadradas nas oportunidades associadas a alianças estratégicas [18, p. 248].

Existem ameaças às alianças estratégicas, sendo que estas assentam no facto de um terço das alianças estratégicas falham para uma das organizações. Este insucesso deve-se muitas vezes à distorção de valor induzido por uma organização, ou seja, o valor que mostram querer trazer para aliança é superior ao que realmente trazem [18, p. 256].

### 2.1.9 Fatores Críticos de Sucesso

Existem vários fatores imprescindíveis para o sucesso. Esses fatores estão intrinsicamente ligados à combinação das características dos consumidores com a natureza da concorrência. Esta ligação leva à necessidade de responder a dois tipos de questões [6, p. 96]:

- 1) Qual o motivo dos consumidores adquirirem os produtos ou serviços? Porque é que preferem uns produtos em detrimento de outros? Qual o valor que os consumidores atribuem aos produtos?
- 2) O que é que as organizações podem fazer para aumentar o valor dos seus produtos na perspetiva do cliente? Como é que as organizações concorrem entre si?

Desta forma, os fatores críticos de sucesso consistem nas variáveis que geram mais valor para os clientes e que diferenciam os concorrentes na geração desse valor [6, p. 96].

Os fatores críticos de sucesso devem satisfazer três critérios genéricos [6, p. 97]:

- 1) Aplicabilidade a todos os concorrentes: Os fatores que destacam, os concorrentes uns dos outros, são aqueles que as organizações geralmente apostam mais para um determinado setor, logo a criação de valor para os consumidores de um determinado produto é alvo de uma aposta por parte das organizações que oferecem esse produto.
- 2) Relevância decisiva: Nem todos os fatores inerentes às organizações e aos seus produtos são fatores críticos de sucesso. É necessário saber quais os fatores realmente decisivos no sucesso de uma organização.
- 3) Possibilidade de controlo pelas empresas: Existem características dos produtos que estão sob controlo das organizações. As variáveis que são decisivas e que proporcionam um valor elevado para os consumidores providenciando diferenciação da concorrência é as que devem ser consideradas fatores críticos de sucesso.

Freire (2008) defende que [6, p. 99]:

“O primeiro passo na formulação de uma visão estratégica consiste na identificação das tendências do meio envolvente contextual e transaccional, bem como das suas implicações para a indústria.

Em seguida devem ser analisadas de uma forma dinâmica as condições de atratividade, a estrutura competitiva e os fatores críticos de sucesso de cada segmento de mercado. Desta forma conseguir-se-á ter uma perspetiva completa do enquadramento do negócio e das oportunidades e ameaças potenciais que se deparam a todos os concorrentes.”

### **2.1.10 Estratégias Consideradas**

Porter identifica, no seu livro “Competitive Strategy”, três estratégias genéricas que podem ser utilizadas pelas empresas para conseguir vantagens competitivas em relação aos seus concorrentes e a longo prazo conseguir uma boa posição no mercado:

- 1) **Estratégia de Custo:** As empresas que seguem esta estratégia têm como objetivo minimizar gastos de todo o processo de fabricação, divulgação e distribuição do produto. Tendo como principal vantagem, em relação aos seus concorrentes, um preço competitivo.
- 2) **Diferenciação:** A estratégia por diferenciação visa a diferenciação do produto ou serviço em relação aos produtos dos seus concorrentes. Isto pode ser conseguido com um investimento no melhoramento da imagem e da marca. O objetivo principal é oferecer produtos diferenciados.
- 3) **Estratégia de Foco:** A estratégia de foco resume-se na escolha segmentos ou nichos específicos de mercado por meio da diferenciação ou dos custos.

As estratégias descritas adiante não são alvo de uma descrição intensiva. Este facto deve-se à tentativa de procurar simplificar o processo de resposta ao questionário e a análise dos resultados e por isso manteve-se as estratégias em níveis de detalhe baixo e que fosse possível um inquérito ao maior número de organizações possíveis, dentro do âmbito do estudo. Por esse, pretende-se manter com a descrição das estratégias uma perspetiva do conhecimento necessários aos inquiridos.

### ***Estratégia de Preço de Produto***

A estratégia assente em preços dos produtos/serviços, esta estratégia enquadra-se na estratégia de diferenciação e deve ser utilizada para alcançar quatro pontos fundamentais [22, p. 171]:

- 1) Alterações no lucro.
- 2) Alterações no número de vendas ou crescimento.

- 3) Alteração no fluxo de caixa líquido.
- 4) Manutenção das vendas, lucro ou fluxo de caixa.

É importante referir que esta estratégia por si só consiste em diferenciar determinado produto dos produtos dos seus concorrentes. É sobre esta perspetiva que os gestores são questionados sobre esta estratégia. Embora se entenda que se existirem estratégias utilizadas especificamente para permitir uma diminuição de preços, que estas podem estar dentro do âmbito das estratégias de custos.

Apesar do número de vendas ser mais fácil medir que o lucro, este tipo de estratégia pode levar a que existam derrapagens indetetáveis num curto prazo. A estratégia de preços com o objetivo de aumentar ou manter o fluxo de caixa positivo pode estar associada a uma necessidade específica e liquidez [22, p. 171].

Geralmente, a redução de preço está relacionada com um aumento do número de vendas, podendo verificar-se ou não um aumento do lucro. A necessidade do aumento do número de vendas pode estar ainda associada à pretensão de se desfazer de inventário, por exemplo, para posteriormente colocar no mercado uma nova versão do produto.

Por outro lado, o aumento do preço dos produtos pode ter a ver com um aumento dos custos da matéria-prima. Geralmente esta estratégia é aplicada com a entrada de uma nova versão do produto e aproveitar a vantagem competitiva do novo produto. Esta estratégia pode ser utilizada apenas para aumentar o volume de negócios, mas é preciso ter em atenção que um aumento de preços pode levar a uma descida significativa dos números de vendas, podendo não compensar no resultado líquido.

O objetivo desta estratégia estar no questionário deve-se ao facto de ser uma estratégia amplamente utilizada pelas micro e pequenas organizações e pode ter um impacto significativo quer no volume de negócios quer no lucro. Esta estratégia pode ser de fácil aplicação, mas deve ser aplicada cuidadosamente uma vez que tem um impacto direto no comportamento dos consumidores.

### ***Estratégia de Qualidade de Produto***

Geralmente a qualidade de um produto está aliado a uma vantagem competitiva, quer da própria organização quer da concorrência, isto é, ou se tem uma qualidade superior aos concorrentes e daí

se obtém uma vantagem competitiva ou então existe necessidade de igualar a qualidade que os concorrentes oferecem. Esta estratégia enquadra-se na estratégia de diferenciação e na estratégia de custos, dependendo do objetivo ser o aumento ou a diminuição de qualidade, respectivamente.

O grande problema de se ter uma estratégia que aposte na qualidade dos produtos é o facto de isso geralmente trazer custos elevados. O aumento qualidade dos produtos pode ter um custo que transforme um produto rentável num produto não rentável. Desta forma a aplicação desta estratégia deve ser ponderada com cuidado. No entanto não oferecer a mesma qualidade que os nossos concorrentes podem levar a uma perda de vendas significativa ao longo do tempo.

No entanto é necessário verificar se na realidade o aumento de qualidade tem impacto significativo na satisfação dos clientes. Aumentar a qualidade pode levar a um aumento de custos que não se reflete nas vendas, ou seja pode não ser importante para os consumidores um aumento no nível da qualidade, mais ainda se o produto já tiver a qualidade desejável.

Desta forma a redução de qualidade pode ser tida como uma estratégia a considerar. Se uma redução de qualidade não tiver um impacto na satisfação do cliente, mas tiver um impacto significativo nos custos.

### ***Estratégia de Redução de Custos***

A estratégia de redução de custos é geralmente designada por estratégia de liderança de custos. Normalmente esta estratégia está inerente à redução do preço dos produtos. Se a organização conseguir produzir com custos menores que a concorrência pode ganhar uma vantagem competitiva no mercado diminuindo o preço dos seus produtos. Como o nome indica esta estratégia enquadra-se na estratégia de custos.

Esta estratégia é geralmente utilizada em mercados específicos, por localização, tipo de cliente ou por segmento de produto. Uma organização que utilize a estratégia de liderança de custo compete diretamente com o líder de custos do respetivo segmento, onde pode operar sem a desvantagem do custo. O líder de custo tende a ter lucros acima da média [9, p. 158].

Os gestores ao utilizar a estratégia de liderança de custo têm que combinar sub-estratégias para tornar possível o sucesso na aplicação dessa estratégia. As sub-estratégias inerentes ao sucesso da



liderança de custo passam por incorporar gestão de materiais e processos tecnologicamente avançados para permitir uma otimização na produção [9, p. 160].

A redução de custos está geralmente relacionada com o aumento nos resultados líquidos permitindo uma melhor sustentabilidade e uma possível canalização dos resultados para investimentos em outras estratégias.

### ***Estratégia de Investimento***

Muitas das vezes, as estratégias envolvem a utilização de capital em investimentos de aplicação de curto e longo prazo. Estas estratégias estão associadas a análise de orçamentos e custos/benefícios que determinam as características dessas estratégias e que avaliam critérios de monitorização com ênfase nas estratégias de nível de negócio. É necessário avaliar o impacto financeiro dos investimentos estratégicos com objetivo de definir uma estrutura financeira prévia à implementação da estratégia. Os objetivos financeiros, assim como planos de ação são necessários para definir indicadores que permitam avaliar a implementação da estratégia [22, p. 174]. Esta estratégia geralmente enquadra-se na estratégia de custos. Muitas das vezes o investimento é feito em máquinas da linha de produção que pode providenciar um aumento da produção a custos mais baixos. No entanto o investimento pode visar o aumento da qualidade dos produtos e assim enquadrar-se na estratégia de diferenciação.

Os investimentos podem ser classificados da seguinte forma [22, p. 175]:

- 1) Redução de custo: Muitas vezes os investimentos são feitos em tecnologia ou em equipamento para aumentar a eficiência de forma a reduzir os custos ou aumentar a produção mantendo os custos e, por conseguinte, aumentar o lucro.
- 2) Manutenção: Nesta categoria é incluída a necessidade de trocar de equipamento de forma a manter a eficiência, mas não existe alteração estratégica.
- 3) Desenvolvimento ou entrada em mercados: Estão incluídas o investimento em campanhas de divulgação para expansão ou entrada em novos mercados.
- 4) Desenvolvimento de produtos: O desenvolvimento de novos produtos ou a alteração de produtos existentes enquadra-se nesta categoria.

- 5) Conformidade: Ajustamento das características de produtos com intuito de corresponder a alteração de regulação governamental ou por motivos de contratos de seguros.
- 6) Variados: os que não se enquadram nas categorias acima descritas são classificados como variados, por exemplo a alterações na estrutura de escritórios ou programas de motivação dos empregados.

Os investimentos devem ser analisados pelos módulos organizacionais que deles beneficiam, uma vez que a experiência inerente a operacionalização permite que os gestores de nível intermédio identifiquem lacunas nos planos projetados. Às vezes as projeções podem não ser realísticas devido a detalhes inerentes às equipas que devem implementar as estratégias, por exemplo por falta de competências. Estes problemas podem não ser facilmente identificados por quem não está diretamente ligado às equipas que terão de implementar a estratégia.

A seleção de investimentos está dependente do orçamento e liquidez existente na organização, ou seja da sua capacidade financeira. Pode não existir financiamento para executar todos os investimentos estratégicos planeados, dessa forma é necessário analisar os investimentos prioritários, assim como o seu retorno [22, p. 175].

Esta análise é significativamente importante, uma vez que as estratégias a serem implementadas podem ter um impacto significativo, quer na estrutura financeira quer na estrutura de produção. Uma avaliação mal feita das estratégias prioritárias e por conseguinte dos investimentos a serem feitos podem comprometer os resultados esperados da aplicação das estratégias. Por exemplo uma aposta numa campanha de divulgação dos produtos, sem existir um aumento de produção, pode levar que a organização se veja impedida de fornecer o número de produtos exigidos pelo mercado, podendo criar uma má imagem nos consumidores e não conseguindo atingir a potencialidade total da campanha de divulgação.

A raridade da utilização de técnicas e ferramentas na avaliação dos investimentos por parte dos investidores. No entanto defendem, que a utilização destas técnicas e ferramentas estão inerentes ao ajustamento e configuração dos investimentos até estes terem o retorno esperado. Os investimentos existentes por parte das organizações têm efeitos ocultos que é de difícil avaliação no investimento [23, p. 125].

### ***Estratégia de Financiamento***

As estratégias de financiamento são geralmente executadas quando existe uma necessidade de financiamento por parte de entidades financeiras, como as entidades bancárias. Geralmente essa necessidade está inerente a projetos de investimento onde é esperado tirar um retorno maior que o financiamento obtido e juros correspondentes. Esta estratégia geralmente visa a aplicação da estratégia de investimento.

Por outro lado, o financiamento pode ser conseguido através de um aumento de capital, quer pelos acionistas já existentes, quer por novos acionistas, ou seja, novos investidores. O aumento de capital pode permitir que a organização se financie sem aumentar os seus custos de financiamento, correspondente aos juros que teria de pagar se optasse por um empréstimo financeiro. Mas tem o inconveniente de os atuais acionistas perderem alguma da sua quota da organização ou de assumirem o risco ao colocar o seu próprio capital.

A estratégia financeira pode estar inerente a uma reestruturação da dívida. Por exemplo uma organização que tenha pedido um empréstimo para um investimento num momento temporal de alguma instabilidade económica e por conseguinte de alguma fragilidade financeira. Esse empréstimo pode ter inerente uma taxa de juro mais elevada do que seria de esperar num momento de crescimento económico. Se essa empresa após algum tempo ganhou alguma consistência financeira com o investimento feito, pode renegociar as taxas de juro associados ao empréstimo com a respetiva entidade. Esta renegociação pode permitir uma diminuição nos gastos de financiamento significativa.

A estrutura financeira está diretamente relacionada com as estratégias globais da organização. Devem ser incluídos indicadores explícitos nos critérios das estratégias utilizadas. A alocação de capital às respetivas estratégias deve vir sempre acompanhado de uma análise de risco inerentes às respetivas estratégias [22, p. 173].

Martins, Cruz, Augusto, Silva e Gonçalves(2009) descrevem no livro “Manual de Gestão Financeira Empresarial” outros instrumentos que permitem a obtenção de financiamento tal como o papel comercial, clientes/fornecedores, *factoring*, empréstimo obrigacionista e *leasing*.

Estes tipos de financiamento não são geralmente utilizados por pequenas organizações, ou pelo menos em valores significativos. Quando são utilizadas, como é o caso do *factoring* ou *leasing*, geralmente não estão aliadas a uma estratégia de financiamento.

### ***Estratégias de Diversificação ou Especialização de Produto***

A diversificação assenta em introduzir novos produtos em novos mercados. Contudo separa as estratégias de extensão de produto e extensão de mercado da diversificação. Extensão de produto significa uma introdução de novos produtos nos mesmos segmentos de mercado e extensão de mercado significa colocar os produtos já existentes em mercados novos. No questionário colocou-se diversificação para englobar as três estratégias distintas [6, p. 218]. Esta estratégia enquadra-se na estratégia de foco.

Existem seis razões para a diversificação ser utilizada por parte das organizações [6, p. 359]:

- 1) Capitalizar nas suas competências centrais: Aproveitar as vantagens competitivas de forma transversal aos produtos da organização. Esta capitalização tem um impacto significativo estratégico caso seja um fator crítico de sucesso.
- 2) Aumentar o poder negocial: Permitir a imposição de melhores condições negociais, quer em fornecedores quer em clientes, que permitam um melhor desempenho nos resultados.
- 3) Partilhar custos: Tornar os ativos tangíveis e intangíveis transversais na sua utilização por parte da organização. Os custos desses ativos podem ser partilhados entre os diferentes módulos organizacionais.
- 4) Balancear recursos financeiros: Aproveitamento da vantagem de diferentes produtos/serviços poderem ter fluxos de caixa diferentes, podendo trazer uma maior estabilidade aos fluxos de caixa existentes.
- 5) Manter o crescimento: A entrada em novos negócios pode levar a um crescimento onde existia uma estagnação. Os ciclos de vida dos diferentes produtos pode compensar e estabilizar a diminuição das vendas em produtos em fim de vida.

- 6) Reduzir o risco: A diminuição do risco pode estar associada a variabilidade das receitas nos vários negócios. Ter negócios contra cíclicos pode levar a uma estabilidade financeira.

São identificados 5 pontos importantes no sucesso da diversificação [6, pp. 363-366]:

- 1) A nova indústria estar em desequilíbrio: O desequilíbrio existente entre a procura e a oferta, notável sobretudo em sectores emergentes ou de rápido crescimento, pode apresentar oportunidades de entrada para novos concorrentes.
- 2) A organização beneficiar de menores custos de entrada: Através da partilha de custos referido anteriormente, nem que esses custos provenham de fontes intangíveis como é o caso por exemplo de uma marca com uma boa reputação noutra sector de mercado.
- 3) A retaliação esperada seja fraca: A retaliação por parte dos concorrentes existentes no mercado possa prejudicar esses mesmos concorrentes, forçando-os a serem passivos em relação à entrada de novos concorrentes.
- 4) A organização ter alguma competência distinta que influencie a evolução estrutural da indústria onde diversifica: Aqui entram as vantagens competitivas que a organização possa ter sobre as suas concorrentes, nomeadamente no processo de inovação dos produtos ou processos
- 5) A entrada no negócio fortalecer a posição da organização noutras indústrias: Por exemplo a entrada de novos produtos poder fortalecer a imagem global da organização.

A diversificação pode, no entanto, trazer problemas sobretudo quando a diversificação induz uma perda de competitividade ou quando induz um aumento de custos que não compensa a entradas de novos produtos ou novos mercados.

A especialização de produtos/serviços defende o contrário da diversificação, isto é, reduz os produtos/serviços disponíveis por parte da organização. Geralmente esta estratégia é aplicada quando a organização é privada de alguma competência chave para os produtos/serviços em questão, por exemplo, uma microempresa pode ter alguma dificuldade em obter capital humano

qualificado para serviços que careçam de algum tipo de creditação. Outro motivo para se aplicar esta estratégia é os custos de certos produtos/serviços não compensarem o preço de venda.

Normalmente as organizações que optem por esta estratégia direcionam-se para um nicho de mercado específico. A aplicação desta estratégia requer algum cuidado e análise dos produtos/serviços a serem eliminados. Alguns dos produtos podem não ter um impacto significativo nos lucros, mas podem ter sinergias com outros produtos/serviços vendidos pela organização, por exemplo uma loja que venda esquentadores a preços perto dos preços de custo e que leve uma certa quantia por instala-los, deixar de vender os esquentadores por levar a que o número de instalações baixe significativamente.

### ***Estratégia de Aumento ou Redução de Mercados***

A formulação estratégica deve começar sempre por uma visão comercial, isto é definir quais os produtos a vender e quais os segmentos de mercados a ocupar. Neste sentido é importante analisar as necessidades dos consumidores e as ações concorrenciais induzidas no mercado. O reforço da adequação estratégica é importante devido ao dinamismo induzido pelo mercado [6, p. 212]. Esta estratégia enquadra-se na estratégia de foco.

A comercialização de mais de um produto/serviço por parte de uma organização induz a necessidade de definição dos mercados adequados para cada um desses produtos/serviços. A atribuição de produtos/serviços de forma errática aos diferentes mercados disponíveis podem ter impacto negativo significativo nos resultados esperados, quer pela parte dos custos, quer pela parte das vendas.

A vertente de custos associados à colocação de produtos em mercados não adequados, leva muitas vezes as organizações a insistir nessa colocação e aumentar os seus custos. Por outro lado, mesmo que a organização não opte por aumentar os seus custos, já teve os custos desnecessários com essa colocação.

Se o mercado atribuído para os produtos não for o adequado o resultado das vendas pode não estar de acordo com o esperado, pelo que pode levar a organização a não ter os resultados desejados com determinado produto e abandonar a comercialização do produto cedo demais.

Freire(2008) defende a criação de uma matriz produto-mercado que identifique as necessidades dos consumidores *versus* os possíveis mercados ou segmentos de mercado. Esta matriz deve relacionar os produtos/serviços com os respetivos mercados-alvo, permitindo uma visão global dos vários mercados e das necessidades dos consumidores a satisfazer [6, p. 212]. Devem ser constituídas as matrizes produto-mercados da perspetiva dos concorrentes, permitindo a identificação de áreas de inferioridade ou superioridade relativa [6, p. 213].

### ***Estratégia de Sinergias Comerciais***

As sinergias com parceiros comerciais ou parceiros tecnológicos são importantes quando se coloca novos produtos em novos mercados, com o intuito de permitir que a organização obtenha competências nas novas áreas de atuação [6, p. 213]. Esta estratégia pode enquadrar-se em qualquer uma das estratégias definidas por Porter, dependentemente de como são executadas as sinergias comerciais.

As estratégias de cooperação entre organizações podem trazer vantagens competitivas para os intervenientes. No entanto referem que apenas 50% a 70% das parcerias têm um grau de satisfação igual ou superior ao pretendido. Com o tempo a possibilidade de conflitos nos objetivos aumenta, criando fricção entre as organizações da parceria. Sendo que cada vez mais as organizações fazem parcerias para obter melhor desempenho nos resultados [17, pp. 126-127].

São indicadas algumas razões para que as parcerias sejam formadas [17, pp. 127-128]:

- 1) Obter capacidade de produção e/ou tecnológicas.
- 2) Obter acesso a mercados específicos
- 3) Para reduzir o risco financeiro
- 4) Para reduzir o risco político
- 5) Para alcançar ou assegurar vantagem competitiva

Uma parceria comercial entre organizações é mais comum do que a maioria das pessoas pensam. Por exemplo a utilização de um método patenteado para produção de um produto pode ser visto como uma parceria comercial. Wheelen(2002) defendem que existem alguns pontos que devem ser tomados em consideração para as parcerias terem o sucesso desejado [17, p. 130]:

- 1) Os objetivos estratégicos devem ser transparentes para as organizações intervenientes. O valor da parceria deve ser partilhado por todos os intervenientes.
- 2) Os objetivos devem ser compatíveis entre todos os intervenientes.
- 3) Cada interveniente deve ter competências e capacidades com o necessário para a parceria.
- 4) Os riscos associados a cada parceiro devem ser identificados. Deve-se saber lidar com esses riscos.
- 5) Deve ser muito bem definido o papel de cada interveniente na parceria
- 6) Devem ser minimizadas as diferenças culturais através de incentivos adequados.
- 7) Deve existir flexibilidade na negociação da parceria.
- 8) Deve ser definido até quando a parceria deve existir, podendo ser de forma temporal ou através dos objetivos ou indicadores atingidos.

A estratégia de sinergias pode ser importante na subsistência ou crescimento de uma organização, mas também pode ter um impacto não desejado na organização. Por isso é necessário analisar cuidadosamente os parceiros e a parceria a ser criada e avaliar a relação de custo/benefício dessa mesma parceria.

### ***Estratégia de Divulgação de Produtos***

As estratégias de divulgação de produtos ou serviços fornecidos pelas micro ou pequenas empresas está limitada sobretudo à capacidade financeira para implementar este tipo de estratégia. Desta forma a estratégia de divulgação de produtos ou serviços é geralmente praticada numa escala pequena e sobretudo em ambientes adequados, ou seja, a localização alvo para a divulgação está dentro do âmbito geográfico ou segmento de mercado onde os produtos da organização estão presentes. Esta estratégia enquadra-se na estratégia de diferenciação.

Cada vez mais as micro e pequenas empresas utilizam a internet e as redes sociais para aproveitarem fazer uma divulgação dos seus produtos e serviços de forma sistemática e a custos reduzidos. Geralmente a visibilidade crescente é sustentada num grupo de pessoas que já conhece os produtos ou serviços. Estas plataformas permitem também uma divulgação, por parte dos



clientes de críticas, e experiências inerentes à utilização dos produtos e serviços. O aproveitamento dessas críticas pode ser importante para melhoramento e aperfeiçoamento dos produtos oferecidos pela organização.

Estas estratégias de divulgação, seja pela internet ou por exemplo pela divulgação através panfletos ou anúncios de jornal, geralmente visam aumentar o número de clientes e por conseguinte um crescimento do volume de negócios.

### ***Estratégia de Reorganização Estrutural***

Freire (2008) defende que a estrutura organizacional é constituída pelo “padrão de relações que une todos os recursos”. A importância da estrutura organizacional é elevada quando se trata de definir e implementar estratégias, especialmente no enquadramento dos recursos da organização na integração dos esforços globais. São identificados 3 fatores em que a estrutura de uma organização pode ser avaliada [6, pp. 452-453]:

- 1) Formalização: Importância da explicitação sobre regras e procedimentos a organização.
- 2) Centralização: Forma e nível a que são tomadas as decisões na organização
- 3) Complexidade: Hierarquização vertical e horizontal da organização.

Esta estratégia enquadra-se na estratégia de custos. Geralmente a reorganização da empresa visa uma redução de custos ou um melhor aproveitamento dos recursos humanos.

A formalização contribui para a minimização da incerteza organizacional. Por outro lado, a definição de regras, funções, relações de autoridade e responsabilidade têm impacto negativo na iniciativa pessoal, tomada de risco e espírito de inovação na organização. Desta forma deve ser definido diferentes níveis de formalização para diferentes áreas de trabalho [6, p. 453].

A centralização de uma organização facilita o controlo e a execução das atividades da organização, sendo mais centralizada quanto mais alto for o nível hierárquico que tem a responsabilidade de tomar decisões. Por outro lado, pode induzir tempos de resposta demasiado elevados em ambientes dinâmicos e afetar negativamente a motivação dos elementos de níveis hierárquicos inferiores [6, p. 454].

A complexidade está inerente a três elementos: Dispersão espacial, diferenciação vertical e diferenciação horizontal. Sendo que a dispersão espacial foca-se nas localizações e mercados geográficos em que a organização está presente. Quanto mais elevada for a dispersão espacial mais complexa será a estrutura da organização. A diferenciação vertical está associada ao número de níveis hierárquicos existentes na organização, quantos mais forem os níveis hierárquicos maior é a complexidade da organização. A diferenciação horizontal é induzida pelos níveis de especialização das tarefas. Quantos mais níveis de especialização, mais grupos existem e maior será a complexidade da organização [6, p. 454].

A reorganização estrutural da organização pode permitir uma redução de custos baseadas na necessidade de controlo, mas também no aproveitamento de recursos em outras áreas onde estes são precisos. Em micro e pequenas esta estratégia pode ser aplicada com efeitos significativos nos resultados, por exemplo, por questões de sazonalidade, ou por diferentes grupos internos poderem crescer a ritmos diferentes ou ter desempenhos diferentes.

### ***Estratégia de Renegociação com Fornecedores***

A estratégia de renegociação com fornecedores está associada ao poder de escolha de novos fornecedores. A aplicação desta estratégia pode ter um impacto significativo nos resultados, sobretudo quando está associado um aumento da compra de produtos ou serviços do respetivo fornecedor. Esta estratégia geralmente enquadra-se na estratégia de custos. No entanto a renegociação com os fornecedores pode dar-se com foco na qualidade dos materiais fornecidos e enquadrar-se com a estratégia de diferenciação.

Inerente a esta estratégia pode estar a negociação de exclusividade na obtenção de produtos fornecidos pelo fornecedor. Por exemplo quando um fornecedor fornece vários produtos de um segmento de mercado e a organização opta por comprar esses produtos ao respetivo fornecedor, permitindo uma redução dos custos com base em descontos de exclusividade.

Esta estratégia assenta de alguma forma nas relações entre a organização e os seus fornecedores, pelo que é importante a confiança por parte dos fornecedores na organização. Desde a política de pagamentos até aos prazos de entrega podem ser pontos importantes na consideração da renegociação com os fornecedores.

## 2.2 Dados Económicos

Neste capítulo descreve-se e discute-se o ambiente económico em Portugal durante um intervalo de tempo que engloba os anos inerentes aos dados do estudo. É importante que se perceba que nos modelos não entram as variáveis económicas. Para considerarmos a utilização das variáveis económicas no estudo seria necessário um elevado número de recursos, quer humanos, quer temporais. Seria necessário que existissem reuniões específicas com os gestores e uma verificação exaustiva das respostas dadas no questionário. O estudo deveria englobar vários tipos de ambiente económicos que poderiam levar um número elevado de anos. Devido a este facto seria praticamente impossível fazê-lo numa tese de doutoramento.

A análise do ambiente económico, segundo uma serie temporal, permite identificar os anos em que o ambiente económico se manteve mais ou menos estável. Esta identificação permite que sejam escolhidos os anos mais propícios para o estudo sem recorrer a variáveis económicas.




Figura 2.3: Dados Económicos - Rendimento dos Particulares e Consumo Privado

O consumo é o ato económico que tem como objetivo a satisfação de uma determinada necessidade. O consumo das famílias designa a parte do rendimento disponível que não é utilizado para poupança. O consumo privado refere-se a todas as despesas feitas pelos particulares em bens e serviços.

## ENQUADRAMENTO TEÓRICO

O rendimento disponível é o total das receitas recebido por um indivíduo, ou família, durante um determinado período. O rendimento disponível tem como componentes as receitas provenientes do trabalho, da propriedade (rendas, juros e dividendos), as transferências internas, onde se enquadram os subsídios estatais, e as transferências do exterior, como por exemplo as remessas dos imigrantes.

O rendimento disponível proveniente das remunerações do trabalho são todas as receitas provenientes do trabalho em forma de salário ou pagamentos.

Em 2011 o rendimento disponível dos particulares decresce -3.67%, em relação a 2010. Tendência que se mantém em 2012 com um decréscimo de -3.59%, em relação a 2011. Nos anos de 2013 e 2014, existe uma redução menos significativa, quase a roçar a estabilidade, com -0.19% e -0.17%, relativamente ao ano anterior. Em 2015 existiu um crescimento de 3.41% do rendimento disponível dos particulares, mas ainda assim, ficando abaixo dos valores de 2011. Só em 2017 é que o rendimento disponível ultrapassa os valores obtidos em 2010.

Para o consumo privado, a tendência entre o ano de 2011 e 2013, inclusive, mantém a tendência do rendimento disponível. Em 2014 verifica-se um crescimento de 2.62% e em 2015 um crescimento de 3.22%. Só em 2016 é que o valor do consumo privado ultrapassa o valor do consumo privado de 2010.




Figura 2.4: Dados Económicos - Mercado de Trabalho

Relativamente ao mercado de trabalho (emprego total), nos anos de 2011, 2012 e 2013 existiu uma redução do emprego de -2.52%, -5.34% e -2.49%, respetivamente. Em 2014 e 2015 existiu uma ligeira recuperação de 1.62% e 1.90%, respetivamente. Só em 2018 é que o emprego igualou os níveis de 2010.




Figura 2.5: Dados Económicos - PIB, Consumo, Importações e Tx Poupança

As exportações, que representam a venda a outros países, constituem uma componente da despesa, uma vez que, apesar de não representarem bens e serviços consumidos internamente, constituem produto realizado no país. As importações que resultam da aquisição e utilização de bens e serviços que foram produzidos externamente ao país, não constituindo produto interno do país.

Cada indivíduo ou família decide como dividir o seu rendimento disponível entre consumo e poupança. A poupança é a diferença entre o rendimento disponível e a despesa em bens de consumo, sendo igual à variação da riqueza do indivíduo ou família. A decisão entre consumo e poupança pode ser vista como uma decisão entre consumo no presente e consumo no futuro.

## ENQUADRAMENTO TEÓRICO




Figura 2.6: Dados Económicos - Volume e variação do PIB

Durante o ano de 2011 verificou-se uma redução do PIB em relação a 2010, na ordem os -1.95%. No ano de 2012 notou-se uma forte redução, com um decréscimo de -4.43%, em relação a 2011. Em 2013 e 2014 o PIB sofreu uma ligeira recuperação, em relação aos anos anteriores, com um aumento de 1.31% e 1.52%, respetivamente. Em 2015 verificou-se um forte aumento no PIB com um crescimento de 3.81%, em relação a 2014., mas ainda assim 0.06% abaixo do que foi registado em 2010.




Figura 2.7: Dados Económicos - Índice de Confiança

Informações sobre as expectativas das famílias relativamente à evolução do futuro do ambiente económico podem ser obtidas a partir dos indicadores de confiança do consumidor [24, p. 21]. A confiança do consumidor é frequentemente associada como uma força motora fundamental da economia. De acordo com o estudo de Fuhrer (1993), quando os consumidores estão confiantes, existe um estímulo na economia, quando estão inseguros, a economia tende a retrair-se. Fisher e Statman (2003) evidenciam o facto que os consumidores tendem a ser mais confiantes sobre o futuro quando estão confiantes com o presente [24, p. 18].

Fuhrer(1993) ainda revela:

*Confidence, like other, economic statistics, must be interpreted in context. For example, a confidence index could register the same value when inflation is low and unemployment is high as when inflation is high and unemployment is low [25, p. 37].*

O principal indicador que mede o sentimento económico encontrava-se em 95 no final de 2010, sendo que no final 2011 tinha caído para os 75.8. No final do ano de 2012 tinha-se verificado uma ligeira melhoria tendo-se verificado um valor de 79.7 e no final do ano de 2013 o sentimento

económico melhorava significativamente para um valor de 97.4. Durante o ano de 2014 este índice oscilou entre os valores 97.2 e 102.9, acabando o ano com 102.3.

Já o índice de confiança dos consumidores no final do ano de 2010, encontrava-se nos -35.2%. No final dos anos 2011 e 2012 tinha os valores de -43.8% e -43.2%, respetivamente. No final do ano de 2013 registou-se uma melhoria significativa, em relação a 2012, com um valor de -28.9%. Em 2014 e 2015, o índice de confiança do consumidor registava os valores de -17.4% e -12.5%.




Figura 2.8: Dados Económicos - Patrimónios anuais consolidados

O património anual consolidado dos particulares sofre uma redução de -1.16% e -1.05%, nos anos de 2011 e 2012, respetivamente. Nos anos de 2013, 2014 e 2015 sofreu um aumento estável em cada um dos anos, 2.11%, 1.77% e 1.87%, respetivamente. Em 2017 sofreu um aumento significativo da ordem dos 4.85%.

O património anual consolidado do total da economia sofre um decréscimo de -8.78% em 2011. Manteve-se estável em 2012, com um aumento de 0.22%, para no ano de 2013 sofrer uma redução de 3.07% e em 2014, um aumento significativo de 5.23%. Em 2015 manteve a estabilidade, com uma redução de -0.17%.



## ENQUADRAMENTO TEÓRICO




Figura 2.9: Dados Económicos - Índice de preços no consumidor

O índice dos preços do consumidor é uma medida que revela o preço médio necessário para comprar bens de consumo e serviços. A sua natureza relaciona-o diretamente com a taxa de inflação ou deflação existente num local relativamente a um intervalo de tempo. Pela lei da oferta e da procura, onde o preço do mercado revela a disponibilidade dos consumidores pagarem por um produto, este índice pode ser relacionado de certa forma com a capacidade e disponibilidade de pagamento por parte do consumidor.

Note-se que nos anos de 2012 a 2015 o índice de preços ao consumidor manteve-se estável entre os valores 99.77 e 100.7, medidos semestralmente. Na segunda metade de 2016 e até 2018 o índice de preços ao consumidor tem mostrado indícios de um crescimento estável.

## ENQUADRAMENTO TEÓRICO




Figura 2.10: Dados Económicos - Empréstimos a famílias.

No gráfico pode verificar-se claramente uma dificuldade acrescida das famílias obterem crédito a partir do ano de 2012 e não voltar, até 2018, a atingir os valores de 2010, apesar de existir um ligeiro aumento a partir de 2016. Por outro lado, também se pode verificar da dificuldade das famílias pagarem os seus créditos uma vez que o rácio de créditos vencido aumentou significativamente de 2011 até 2015, e só atingir valores de 2010 em finais de 2018.




Figura 2.11: Dados Económicos - Taxas de juro - Empréstimos a Particulares (Consumo)

Por último, observa-se as taxas de juro inerentes ao crédito de consumo, pode verificar-se que a acompanhar a dificuldade de obtenção de empréstimos e do pagamento dos mesmos por parte das famílias, verifica-se um aumento das taxas de juro entre 2010 e 2014, manifestando o aumento de risco inerente ao pagamento dos empréstimos. Apenas em 2016 a taxa dos empréstimos ao consumo voltou a níveis de 2009.

“O forte poder explicativo do índice de confiança relativamente ao desemprego tem uma interpretação económica relevante. Pois, se o índice de confiança permite antever quais as expectativas dos consumidores relativamente à sua situação económica, então ao ser previsto um aumento do desemprego isso implica um menor rendimento disponível para consumo, o que acaba por se refletir num crescente pessimismo sobre a economia e perspetivas de crescimento económico futuro. Isto acaba por influenciar a competitividade das economias através da taxa de câmbio e juro, refletindo-se então na confiança negativa sobre a produção industrial, podendo levar a períodos futuros ainda mais recessivos.” [26, p. 45]

A apresentação dos dados permite que se verifique que o comportamento dos consumidores e das famílias teve um certo grau de estabilidade no crescimento não significativo nos anos de 2012 a 2014. Em meados de 2015 nota-se um comportamento adequado ao crescimento económico, ainda

que ténue, em Portugal já com algum significado macroeconómico. Pelo que estes 4 anos se julgam ser ideais para se obter os dados que fundamentam o estudo.

### 2.3 Aplicação de Redes Neurais à Gestão

Nesta secção descreve-se algumas das áreas da gestão onde as redes neuronais são utilizadas. Foram verificados artigos publicados que fazem referência á utilização das redes neuronais nas diversas áreas da gestão. Neste sentido é fácil verificar a ampla utilização das redes neuronais como apoio nas diversas áreas. Pode verificar-se a importância crescente das redes neuronais como apoio informativo nas diversas áreas da gestão.

Contrariamente ás técnicas de programação convencional, as RNAs são capazes de resolver problemas não lineares e mal definidos baseados em composição paralela. Nas últimas duas décadas, a utilização das RNAs foi crescendo significativamente na área da gestão de negócios. Esta evolução não apenas levou a um desenvolvimento de diferentes aplicações científicas, mas também levou a uma intensa exploração de pontos práticos [27, p. 789].

Área de Gestão	Descrição/Citação
Auditoria e Contabilidade	Embora os modelos de redes neurais sejam capazes de lidar com variáveis categóricas com mais valores, a maioria dos autores em auditoria e contabilidade focaram-se em variáveis binárias [27, p. 790].
	A imprensa financeira publicou relatos do potencial das redes neurais artificiais (RNAs) como ferramentas em finanças e contabilidade [28, p. 147].

## ENQUADRAMENTO TEÓRICO

Área de Gestão	Descrição/Citação
Monitorização de Custos	A previsão de custos desempenha um papel crucial nos ciclos de negócios e produtos. Apesar do pequeno número de aplicações encontradas, as redes neurais ofereciam várias vantagens na estimativa de custos em comparação aos métodos tradicionais. Com dados reais, as redes neurais foram capazes de extrair conhecimento e aproximar funções de custos, ou de serem modificadas e treinadas usando novos dados. [27, p. 790].
Análise de Crédito	O financiamento de crédito tem aumentado rapidamente nas últimas duas décadas e as redes neurais emergiram como uma técnica útil na avaliação quantitativa da capacidade creditícia dos sujeitos que solicitam empréstimos [27, p. 792].
Métricas de Clientes	Vários autores no campo do comportamento do cliente, o valor das redes neurais consistia em sua capacidade de imitar a operação do cérebro humano e estimar com precisão o comportamento com base nas características do produto, sem suposições sobre relacionamentos entre variáveis de entrada. Uma ampla gama de aplicações de redes neurais nessa área inclui análise de satisfação do cliente, pesquisa de heterogeneidade ou previsão de gastos [27, p. 792].
Apoio à decisão	Toda atividade comercial é afetada por várias decisões essenciais. Ter um sistema confiável de apoio à decisão, no qual os modelos possam lidar com a incerteza, está-se a tornar uma questão essencial para as empresas no atual ambiente. Comparando com pesquisas anteriores de redes neurais nos negócios, encontramos um grande aumento nos aplicativos de suporte à decisão [27, p. 792].

## ENQUADRAMENTO TEÓRICO

Área de Gestão	Descrição/Citação
Derivativos Financeiros	Como as redes neurais estimaram o preço apenas com base em dados históricos, elas não sofreram vieses sistemáticos resultantes de suposições simplificadas de técnicas de atribuição de preços padrão, como o modelo Black-Scholes. As redes neurais frequentemente alcançavam resultados plausíveis de previsão, apesar da complexidade e natureza interconectada dos mercados de derivativos financeiros. [27, p. 792].
Taxas de Câmbio	Os mercados de taxas de câmbio são estruturas altamente complexas, com informações limitadas sobre as forças subjacentes que influenciam os dados. Vários tipos de arquiteturas de redes neurais e algoritmos de aprendizado foram, portanto, aplicados para prever a magnitude e a direção das mudanças nas taxas de câmbio [27, p. 792].
Análise Financeira	As redes neurais artificiais são frequentemente usadas em muitos problemas de modelação e previsão, principalmente devido às oportunidades de uso de processamento intensivo computacional. Recentemente, elas foram cada vez mais aplicadas na análise de séries temporais financeiras. A principal vantagem do mesmo é a capacidade de aproximar quase qualquer função não linear arbitrária. As RNAs podem fornecer um melhor ajuste, particularmente em séries temporais financeiras com relacionamentos dinâmicos não lineares complexos. No entanto, geralmente é difícil interpretar o significado dos parâmetros e as redes neurais são vistas como modelos de “caixa preta” construídos para o reconhecimento e previsão de padrões. [29, p. 35].

## ENQUADRAMENTO TEÓRICO

Área de Gestão	Descrição/Citação
Dificuldades Financeiras e Falência	Embora os métodos de classificação convencionais sejam muito populares na pesquisa sobre dificuldades financeiras e falências, as redes neuronais têm sido amplamente usadas para projetar modelos de falências [27, p. 792].
Análise de Fraude	A eficácia das redes neuronais na classificação de fraudes financeiras foi examinada por vários autores. Green e Choi [30] e Chen et al. [31] utilizaram com sucesso a rede neuronal de retropropagação convencional como uma ferramenta de avaliação e deteção de fraudes financeiras, enquanto Lei e Ghorbani [32] propuseram algoritmos de classificação para comportamento fraudulento em empresas de comércio eletrônico com base em aprendizagem competitiva melhorada e supervisionada. Estévez et al. [33] desenvolveram um sistema de deteção de fraude em tempo real para clientes de empresas de telecomunicações utilizando redes neuronais para módulo de previsão e regras difusas para o módulo de classificação [27, p. 792]..
Marketing	As RNAs podem ser aplicadas a muitos problemas de decisão de marketing que antes só podiam ser enfrentados por análises estatísticas multivariadas. Problemas típicos são tarefas de segmentação de mercado e modelagem de respostas de mercado, padrões de gastos do consumidor, análise de novos produtos, identificação das características do cliente; marketing direcionado etc. O ponto mais crucial para as atividades de pesquisa no campo do marketing é a falta de aplicativos nos dados de nível individual. Este tipo de problemas é encontrado no contexto do comportamento de compra na tradição de modelos estocásticos de comportamento do consumidor [29, p. 35].

## ENQUADRAMENTO TEÓRICO

Área de Gestão	Descrição/Citação
Produção	A previsão de custos de produção, datas de entrega., controle e otimização da qualidade, domina os problemas de produção. Como os problemas de controle de qualidade correspondem à classificação, a adequação da aplicação de redes neurais artificiais deve ser tão boa quanto as das áreas de finanças e marketing [29, p. 36].
Vendas	Semelhante a muitas séries temporais de negócios, os dados de vendas exibem fortes tendências e padrões sazonais. Por esse motivo, os modelos padrão geralmente carecem das habilidades de extrapolação e levam a distúrbios nos planos de produção. Thomassey and Happiette [34] projetaram um sistema automatizado de previsão de vendas através de redes neurais com base nos dados de um distribuidor têxtil. Ansuji et al. [35] argumentaram que a rede de retropropagação convencional superou o modelo ARIMA com intervenções e forneceu melhores previsões, enquanto o desempenho de previsão fora da amostra de diferentes modelos para vendas no varejo foi apresentado por Alon et al. [36]. Kuo e Xue [37] e Kuo et al. [38] focaram-se na integração de redes neurais convencionais e difusas para melhorar a solução do problema de previsão de vendas em promoção [27, p. 793].
Gestão Estratégica	A pesquisa empírica em sistemas de planeamento estratégico foca-se em duas áreas: o impacto do planeamento estratégico no desempenho da organização e o papel do planeamento estratégico na tomada de decisões estratégicas [39]



## ENQUADRAMENTO TEÓRICO

Área de Gestão	Descrição/Citação
Ações e Obrigações	Devido ao potencial de lucros altos, a previsão dos preços das ações é de grande interesse não apenas para pesquisas académicas, mas também para corretores e investidores. Durante o período investigado, vários modelos de redes neuronais foram apresentados na tentativa de superar técnicas estatísticas convencionais e prever com precisão os movimentos de preços [27, p. 793].

Tabela 2-1: Aplicações de RNAs a áreas de Gestão.

As redes neuronais artificiais têm recebido uma enorme atenção nas últimas duas décadas. Grande parte dos estudos se concentraram em várias disciplinas de negócios, no entanto, apenas um pequeno número de pesquisas foi publicado nessa área. um artigo apresentado por Tkác e Verner (2016) examinou 412 aplicações de redes neurais em diferentes áreas de negócios publicadas entre 1994 e 2015 em periódicos influentes bem conhecidos. Embora os autores investigados tenham aplicado redes neuronais com êxito em tarefas diversas, os resultados indicam que os problemas mais examinados que ocorreram nos estudos foram: dificuldades financeiras e análise de falências, previsão de preço das ações e análise de crédito. O número médio de artigos de análise financeira e derivativos permaneceu aproximadamente o mesmo durante o período examinado [27, p. 797].

Chattopadhyay, et. Al descrevem no seu artigo a aplicação de RNAs na segmentação de mercados em cerca de 100 artigos considerados relevantes. Sendo que a segmentação de mercado tornou-se num conceito fundamental. As publicações dentro desta área têm tido uma tendência em aumentar, o que reflete a importância crescente das RNAs no mundo dos negócios [22].

Shachmurove (2002) publicou um artigo que defendia a utilização das RNA na análise e previsão em modelos com dados não determinísticos. A não linearidade dos problemas das áreas económico-financeiras torna as RNA como possíveis melhores candidatas para serem utilizadas na modelação [40].

Guido, et al. (2011), publicaram um artigo que descreve uma forma de utilização de redes neuronais para focar as campanhas de *marketing* em grupos de indivíduos específicos. Esta forma

permite aumentar o retorno das campanhas em comparação com a utilização de metodologias como análise de regressão múltipla ou regressão logística [41].

Mahbub, et al (2013) publicaram um artigo sobre a abordagem utilizada para prever a procura de produtos utilizando redes neuronais. No seu artigo utilizaram um RNA para prever a procura de produtos em função de vários parâmetros tais como o período anual, publicidade, número de empregados, entre outros. Em comparação com os modelos gerados através da estatística linear, os modelos gerados com RNA demonstraram melhor desempenho. Conclui-se neste artigo que o modelo gerado podia ser utilizado para prever a procura de mobília num mercado competitivo [42].

Abiodun, et al (2018) identificaram um vasto conjunto de aplicações no mundo dos negócios onde as RNAs são usadas. Entre elas estão figuradas áreas de finanças, mercados financeiros, negócios, entre outras. Focando-se também nas características inerentes às RNAs como tolerância ao ruído nos dados e a capacidade de lidar com ambientes não lineares [43].

Bihl, Young and Weckman (2014) antevêm o caminho da utilização das RNAs nas aplicações no mundo dos negócios associada à crescente facilidade da sua utilização. Defendem que existirá uma propensão para se investir em novas metodologias e algoritmos para utilização com grandes e pequenas base de dados [44].

Kraus, et al (2019) publicaram um artigo que analisa a utilização de redes neuronais (DNNs) na análise de negócios e investigação operacional, assim como a sua implicação na gestão. Fomentam a ideia de que as redes neuronais são, comparativamente a outras metodologias de aprendizagem, a melhor metodologia para utilização de conjuntos de dados com elevado número de amostras. Concluem devido ao facto de as organizações terem de lidar com conjunto de dados cada vez maiores, os avanços tecnológicos na análise preditiva podem trazer um melhoramento aos processos de tomada de decisão [45].

A utilização das redes neuronais tem aumentado, ao longo dos anos, na área da gestão. Já não se utiliza apenas para modelar ambientes de previsão através de padrões, como é o caso de previsão do comportamento de ações na bolsa. Mas são utilizadas também como sistemas de apoio à decisão informada. O crescimento do poder computacional aliado à criação e desenvolvimento de algoritmos, com maior eficácia, permite que as redes neuronais enfrentem experiências cada vez

mais ambiciosas. A aceitação das redes neuronais por parte do mundo académico e do mundo empresarial veio trazer um conjunto cada vez mais amplo de novas aplicações nomeadamente no mundo dos negócios.

## 2.4 Árvores de Decisão Aplicados á Gestão

Dentro do vasto universo de utilização as árvores de decisão como sistemas de apoio encontram-se inúmeras áreas inerentes á gestão. Neste capítulo descreve-se algumas das áreas e potencial de utilização das árvores de decisão inerentes ao mundo da gestão. A versatilidade e potencial das árvores de decisão torna apetecível a sua utilização como sistemas de apoio á decisão. O facto de as árvores de decisão serem geradas através de dados previamente comprovados permite uma confiança acrescida nos seus resultados. A visualização dos caminhos percorridos até uma decisão final permite uma elevada compreensão dos motivos que levam a tal decisão. Por estes motivos os gestores tendem a ter uma confiança nos resultados ou uma intuição aumentada sobre que caminho a percorrer para alcançar os resultados desejados, mesmo que isso signifique não aceitar a decisão de uma hipotética árvore de decisão.

Alaminos, et al. (2019) descrevem no seu artigo a aplicação de árvores de decisão de forma a aumentar a precisão de modelos para previsão de crises de dívida soberana. Com previsões acima dos 95% de precisão, pode considerar-se de grande interesse a utilização de árvores de decisão como auxílio a modelos de previsão deste tipo [46].

Em 2004, Ikeda, Kubo e Kobayashi publicaram um estudo baseado na previsão de procura e valorização de negócio com recurso a um modelo baseado em agentes e aplicado a árvores de decisão. Esta metodologia permite o apoio á decisão de um investimento [47].

Höppner, et al. (2018) demonstraram no seu estudo a possibilidade de utilizar árvores de decisão orientadas ao lucro para previsão de rotatividade. Esta metodologia pode ser utilizada para otimizar campanhas de retenção de clientes [48].

Brédy, et al. (2020) descrevem no seu artigo a possibilidade de utilização de árvores de decisão para gerir um lençol freático de forma a otimizar o uso da água baseado num sistema previsional. O que significa que as árvores de decisão podem ser utilizadas de forma a otimizar um sistema operacional [49].

Chen, et al. (2020) fundamentam no seu artigo uma metodologia que permite a investigação de padrões associados à relação entre o volume de tráfego aéreo e o desenvolvimento macroeconómico. O artigo assenta em técnicas de *data-mining* usando classificação de k-médias e árvores de decisão [50].

Na área da publicidade, Wang e Hong (2019) descrevem uma avaliação de desempenho de anúncios *online* utilizando uma abordagem de filtro gaussiano e árvores de decisão. A avaliação de desempenho de tal estrutura é útil para as empresas que visam mitigar custos desnecessários e que ao mesmo tempo queiram potenciar o seu lucro. O estudo permite concluir que a metodologia usada pode alcançar, com grande grau de precisão, previsões sobre o desempenho de anúncios *online* [51] [52].

Zhou, et al. (2019) utilizam árvores na sua pesquisa de metodologia previsional sobre o comportamento de índices de mercados de ações. O modelo utilizado com recurso a árvores de decisão não apenas supera os outros modelos, mas também mostra estatisticamente e economicamente significativas para explorar estratégias simples de negociação, quando o custo da transação é levado em consideração [53].

Osipovs (2019) apresentou no seu artigo uma forma de filtrar currículos vitae numa companhia de transportes, utilizando árvores de decisão. O próprio algoritmo não garante uma classificação qualitativa, mas tenta construir a árvore ótima, o que corresponde a decisões feitas por um especialista. Esta metodologia visa apoiar os recursos humanos numa fase inicial do processo de recrutamento [54].

Aguilar-Chinea, et al. (2019) utilizam árvores de decisão para prever a robustez de um planeamento de um cronograma de transbordo de navios. Ou seja, avalia o desempenho do planeamento gerado. De salientar que o modelo resultante tem um bom ajuste, com um coeficiente de determinação de 0,73 para os dados de validação (1 seria uma previsão exata) [55].

A série de literatura revista indica um conjunto de áreas ligadas à gestão onde as árvores de gestão podem ou são utilizadas. Um padrão comum na utilização das árvores de decisão é que estas são sobretudo utilizadas como auxiliares de uma outra metodologia, no entanto é compreensível a importância destas como apoio à decisão. O potencial de utilização e desempenho é algo declarado no desempenho descritos nos artigos referidos. E a versatilidade da possibilidade de utilização nas

diferentes áreas, desde recursos humanos a estratégia operacional, indiciam um potencial de utilização extraordinário.

## 2.5 Previsão de Resultados Financeiros

Nesta secção descreve-se e identifica-se as áreas financeiras onde a previsão é mais utilizada. Sendo que a versatilidade da previsão financeira está sobretudo associada á previsão do comportamento dos mercados financeiros e á identificação de organizações com problemas financeiros. De um modo geral, são utilizados métodos estatísticos sobre o comportamento financeiro organizacional sobre um período de tempo para identificar comportamentos padronizados que levem a um estado específico. É importante que se perceba que não existindo investigação executada especificamente no que é discutido nesta tese de doutoramento que se tentou de alguma forma perceber o que é feito em áreas relacionadas.

Embora haja períodos em que é possível prever mercados financeiros, a previsibilidade dos mercados financeiros pode não ser possível o tempo todo [56, p. 1].

Os primeiros estudos de séries temporais financeiras foram baseados no pressuposto de que os retornos são independentes. Hoje, vários estudos empíricos mostraram que as séries temporais financeiras são ricas em características estatísticas não triviais, como caudas gordas, agrupamento e multi-escala [57, p. 4234].

A imprevisibilidade foi formalizada como variação estocástica intrínseca em uma distribuição conhecida, onde o condicionamento das informações disponíveis não altera o resultado da distribuição incondicional. Isso significa que mesmo uma variável não seja intrínseca, ainda pode ser essencialmente imprevisível, devido à imprevisibilidade extrínseca derivada de mudanças imprevisíveis da própria distribuição e instabilidade imprevisível obtida por meio de distribuições de cauda gorda ou de cauda pesada [58, p. 186]. As três distinções dentro da imprevisibilidade de intrínseca, instância e extrínseca, têm impacto diferente para análises econômicas, modelagem econométrica e previsão [58, p. 193]. A extensão da dependência de uma observação atual em relação às observações passadas pode ser explicada por modelos estocásticos [59, p. 448].

Os mercados financeiros são os sistemas dinâmicos complexos evoluídos, com alta volatilidade e ruído. A análise e previsão de comportamento financeiro, dificuldades financeiras e previsão de falências têm sido objeto de grande interesse para pesquisadores financeiros desde o final da

década de 1960. [60] [61]. Beaver (1966) estabeleceu as bases dos modelos de previsão quando usou um teste t de classificação dicotômica em uma estrutura unidimensional usada para prever o status de falha de uma organização com base em índices financeiros [60] [62, p. 7].

Beaver (1966) é considerado um pioneiro que primariamente utilizou um teste t de classificação dicotômica em estrutura unidimensional e também lançou as bases de modelos de previsão. O teste t serve para testar hipóteses sobre médias de uma variável quantitativa numa dicotômica, ou seja, variáveis que podem ter apenas dois estados. Ele usou índices financeiros de 79 empresas falidas e não-falidas que operavam no mesmo setor e que tinham a mesma quantidade de ativos. Altman (1968), que propôs uma técnica multidimensional conhecida como análise discriminante multivariada (MDA), fosse aplicada em uma amostra de 33 empresas falidas e 33 não-falidas no período de 1946 a 1964. Ele escolheu cinco variáveis que eram as mais relevantes na previsão de falência da empresa: Capital circulante / Total de ativos, Lucros acumulados / Ativo total, Valor de mercado do patrimônio / Valor contábil da dívida total, Vendas / Ativo total. Ohlson (1980) aplicou o modelo Logit, que se baseava nas mesmas premissas do MDA e se popularizou na previsão de problemas financeiros das empresas. Ohlson utilizou para a construção os dados de 105 empresas falidas e 2058 empresas não-falidas no período de 1970 a 1976. Os resultados mostraram que o tamanho, estrutura financeira (total do passivo para o total de ativos), desempenho e liquidez foram determinantes importantes da falência [60].

Altman (1968) identificou um rácio simples - Fluxo de caixa / Dívida total como o melhor preditor de falência. A vantagem de um modelo unidimensional é principalmente sua simplicidade, que não requer conhecimento de estatística [60].

É bastante difícil prever retornos financeiros porque os conjuntos de dados financeiros são caracterizados por serem não estacionários, de natureza não estruturada e de relacionamentos ocultos. No entanto, indivíduos e organizações sempre se dedicaram a prever com precisão vários tipos de retornos financeiros, a fim de desenvolver estratégias de negociação lucrativas e evitar o risco de perdas potencialmente grandes. Nos últimos anos, as redes neurais artificiais (RNAs) demonstraram ser modelos de pesquisa bem-sucedidos para prever mercados financeiros. Modelos de RNA foram desenvolvidos para prever, detetar e resumir a estrutura de variáveis financeiras sem depender muito de suposições específicas e distribuições de erros. Outros pesquisadores

tentaram juntar várias técnicas de inteligência artificial para melhorar o desempenho preditivo das RNAs. [63].

A previsão de resultados financeiros por meio de séries temporais financeiras tem uma dificuldade crescente, porque a natureza apresenta tendências de longo prazo, variação cíclica, variação sazonal e movimentos irregulares. Trabalhar com dados irregulares geralmente está sujeito a grandes erros. Portanto, é um verdadeiro desafio desenvolver modelos realistas para prever resultados financeiros com alguma precisão. Os modelos estatísticos tradicionais usados para previsão financeira eram simples, mas apresentam várias deficiências devido à não linearidade dos dados. [64].

A análise e o desenvolvimento de modelos de previsão do tempo financeiro são, desde há muito, de grande interesse da pesquisa financeira. A teoria estatística desempenha um papel importante na análise de séries temporais financeiras devido ao elemento incerto (Lamberton & Lapeyre, 2000; Ross, 1999; Tsay, 2005) [65, p. 106]. Por outro lado, a previsão do comportamento do mercado de ações tem um grande nível de dificuldade devido às suas não linearidades, natureza altamente volátil, descontinuidades, movimentação de outros mercados de ações, influências políticas e outros fatores macroeconômicos. Embora exista uma correlação significativa econômica e estatisticamente, o comportamento de um mercado de ações é praticamente um ambiente aleatório [66, pp. 371-372].

### **2.5.1 Redes Neurais na Previsão**

*EVolution of recurrent systems with Optimal LINear Output* (Evolino) é um software baseado em redes neurais recorrentes supervisionadas (RNRs) [67]. uso do Evolino RNRs para modelar o mercado de câmbios é comprovadamente um método de previsão confiável. Sua previsão é baseada na distribuição potencial estocástica informativa. Forma e parâmetros da distribuição influenciam a tomada de decisão no mercado de câmbios [68, p. 1163].

Ahmad Bagheri et al. (2014) publicaram um estudo propondo um modelo híbrido de inteligência artificial como um sistema de consultoria comercial. Um sistema híbrido ANFIS-QPSO (Sistema de Inferência Fuzzy Adaptativa baseado em Rede - Otimização de Enxame de Partículas Comportado Quântico) é usado como um método de previsão um passo à frente. Ao implementar e testar o método proposto em dados reais de câmbio, ele poderia prever a direção do mercado e tomar decisões corretas de negociação com aproximadamente 69% de precisão [69]. Atualmente,

também são aplicados para previsão de falências vários tipos de algoritmos heurísticos (redes neurais e árvores de decisão) e registraram melhorias na previsão de problemas financeiros [60]. As RNAs têm algumas limitações para aprender dados de alta dimensão e selecionar um grande número de parâmetros de controle [63].

As RNAs podem ser usadas para modelar dados estatísticos não lineares, como uma ferramenta de tomada de decisão. As RNAs podem ser usadas para modelar relacionamentos complexos, a fim de encontrar um padrão nos dados. As RNAs possuem propriedades peculiares como orientação a dados, autoaprendizagem e auto-adaptativa. Portanto, podem ser usados para desenvolver modelos de previsão sem depender fortemente de suposições específicas e distribuições de erros (Azoff 1994; Demuth e Beale 1998; Refenes 1994) [61].

Um elemento-chave da previsão financeira é a capacidade de construir modelos mostrando a inter-relação dos modelos de dados financeiros e a correlação entre variáveis que podem ser empregadas para melhorar a tomada de decisões financeiras [61]. A RNA não faz suposições sobre a estrutura subjacente [70], do ponto de vista estatístico, as RNAs são análogas aos métodos de regressão não-paramétricos e não-lineares [65, pp. 106-107].

A qualidade demonstrada pelas RNAs no mapeamento não linear é difícil de alcançar com os métodos convencionais. As RNAs têm a capacidade de lidar com problemas complexos de instabilidade estrutural. Esse recurso se deve à capacidade de descobrir relacionamentos não lineares sem suposições sobre a estrutura do ambiente [66, p. 372].

Os métodos baseados em gradiente são um dos métodos de minimização de erro mais amplamente usados para treinar modelos de RNA de retropropagação (*backpropagation*). O algoritmo de retropropagação é uma técnica clássica dependente do domínio para treinamento supervisionado. Ele funciona medindo o erro de saída calculando o gradiente desse erro e ajustando os pesos e desvios da RNA na direção do gradiente descendente. As RNAs baseadas em retropropagação são métodos muito populares para prever o mercado de ações com melhor cálculo, capacidade de englobamento e capacidade de mapeamento não-linear mais forte. Mas o mercado de ações lida não apenas com a não linearidade, mas também com o caos, e é um sistema dinâmico relacionado ao tempo [66, p. 372].



### 2.5.2 Árvores de Decisão na Previsão

As árvores de decisão podem servir para análises qualitativas e previsão, frequentemente utilizadas com base tecnológica. A construção e uso de árvores de decisão baseadas em dados estatísticos é uma disciplina amadurecida e com vantagens, desvantagens, assim como, as suas características são conhecidas [71, p. 41].

Uma ferramenta designada EDDIE (Evolutionary Dynamic Data Investment Evaluator) foi, especificamente, desenvolvida para ajudar os analistas na procura de interações entre fatores, na forma de árvores de decisão utilizando programação genética, e possibilitar decisões financeiras baseadas em previsões financeiras [72].

As árvores de decisão respondem de forma simples e rápida a problemas de decisão de conteúdo previsional, mesmo quando não existe informação suficiente para ser aplicado métodos quantitativos previsionais. Ao utilizar esta metodologia, Lazăr e Lazăr (2015) consideram importante a capacidade de análise, interpretação e síntese de quem a utiliza. Isto significa quem utiliza as árvores de decisão deve conhecer a área de aplicação de forma a estabelecer, com um certo grau de precisão, as ligações e coeficientes importantes para que o objetivo seja alcançado [71, p. 47].

Jeganathan et al. (2017), no seu estudo, com o objetivo de prever a falência das organizações por meio dos resultados financeiros, utilizando o algoritmo C4.5, conseguiram obter uma precisão de 82.9% com árvores de decisão [73, p. 1476]

Shi and Ghedira (2016) propuseram um modelo de previsão para prever as intenções de compra dos clientes em lojas virtuais, onde com as árvores de decisão obtêm uma precisão de 90%. [74]

Mienye, et al. (2019) apontam no seu artigo de revisão um conjunto de autores que ao longo dos anos melhoraram os algoritmos ID3 e C4.5 de forma a obterem um desempenho maior na previsão [75].

As árvores de decisão são utilizadas num número elevado de áreas para modelação de ambientes preditivos, passando por modelos financeiros, como os que foram apresentados anteriormente até modelos de previsão de tempo [76]. Foram demonstradas as capacidades de previsão das árvores de decisão que permitem resultados no mínimo satisfatórios.


### 3 METODOLOGIA DE INVESTIGAÇÃO

#### 3.1 Redes Neurais

Nesta secção irá ser apresentada toda a vertente quer conceptual quer técnica das redes neuronais. Fazendo parte da metodologia utilizada para modelar os ambientes estratégicos necessários para fazer prova da hipótese, julga-se ser necessário descrever o conceito e funcionamento, assim como a parametrização utilizada. Nestas descrições tentou-se ser o mais conciso e claro possível sem entrar em aprofundamentos da matéria, providenciando um conhecimento acessível a todos. Julga-se que o conhecimento aqui transcrito é o suficiente para compreender como as experiências do estudo empírico foram executadas.

##### **Conceito**

As redes neuronais visam emular o comportamento do cérebro humano. O cérebro humano é constituído por cerca de  $10^{11}$  neurónios, onde cada um desses neurónios encontra-se interligado com vários, cerca de  $10^4$ , outros neurónios. A informação transita de neurónio para neurónio através de processos químicos e eletromagnéticos, possibilitando assim quer a propagação da informação quer a alteração de estados dos neurónios.



*Figura 3.1: Esquema de um neurónio biológico*

As redes Neuronais são constituídas por elementos simples interligados que processam dados, com capacidade de aprendizagem a partir dos dados. Apesar da simplicidade de cada unidade de processamento, a utilização de um número elevado de unidades interligadas permite a execução de tarefas complexas [77, p. 163]. As interligações de cada um dos neurónios a estruturas neuronais mais complexas permite um alto desempenho das infraestruturas [78, p. 91].

As redes neuronais artificiais são uma solução consistente e robusta, no que toca a emular funções reais, discretas e mesmo vetoriais. Evidenciando que as redes neuronais estão entre os métodos de aprendizagem mais eficazes para interpretar dados de natureza complexa [79, p. 81].

Com o avanço tecnológico no processamento de dados pelos microprocessadores, atualmente muito mais rápidos e com possibilidade de executar multiprocessamento em tempo real, as redes neuronais tornam-se uma opção viável para análise de dados e providenciar resultados em tempo útil.

Nesta secção tenta-se explicar de forma a ser de fácil compreensão o funcionamento das redes neuronais artificiais (RNAs), evitando a teoria complexa inerente às RNAs. Mediante o vasto universo das redes neuronais, será apenas focado o essencial para uma compreensão da execução do estudo inerente a esta tese de doutoramento, evitando assim a dispersão da matéria sobre este tema.

### ***Modo de Funcionamento*** **Perceptrão**

Um perceptrão é a forma computacional de emulação de um único neurónio. Com diversas entradas emula as várias ligações que permite a comunicação de informação entre neurónios. As diversas saídas permitem ao perceptrão emitir informação e disponibiliza-la para outros perceptrões em camadas mais avançadas, no caso de redes neuronais multicamadas, ou como saída para que possa gerar resultados.

A capacidade informativa de um único perceptrão está restrita a decisões de classificação de um hiperplano. Isto é um único perceptrão tem capacidade de classificar se uma determinada entrada se situa acima ou abaixo de um hiperplano que define a zona de classificação [79].




Figura 3.2: Classificação por perceptron simples

A classificação indicada na Figura 3.2, ou seja classificar como azul(1) ou vermelho(-1), teria uma representação matemática na forma:

$$s(x_1, x_2, \dots, x_n) = \begin{cases} 1 & \text{se } w_0 + w_1x_1 + \dots + w_nx_n > 0 \\ -1 & \text{caso contrário.} \end{cases} \quad (\text{Eq. 3.1})$$

onde:

$s$  é a função de avaliação (saída).

$x_1, x_2, \dots, x_n$  são parâmetros de entrada.

$w_0, w_1, \dots, w_n$  são pesos predefinidos.

A representação gráfica (Figura 3.3) da fórmula matemática do perceptron binário seria de:




Figura 3.3: Representação gráfica de um perceptron binário.

Desta forma o perceptrão binário classifica as entradas com dois valores possíveis 1 ou -1, ou seja uma função de avaliação que retorna valores discretos. A forma de potenciar a informação de saída é alterar a função de forma a torna-la uma função com retorno de outro conjunto de valores, como por exemplo valores contínuos. De uma forma geral ter-se-ia a seguinte representação gráfica (Figura 3.4):

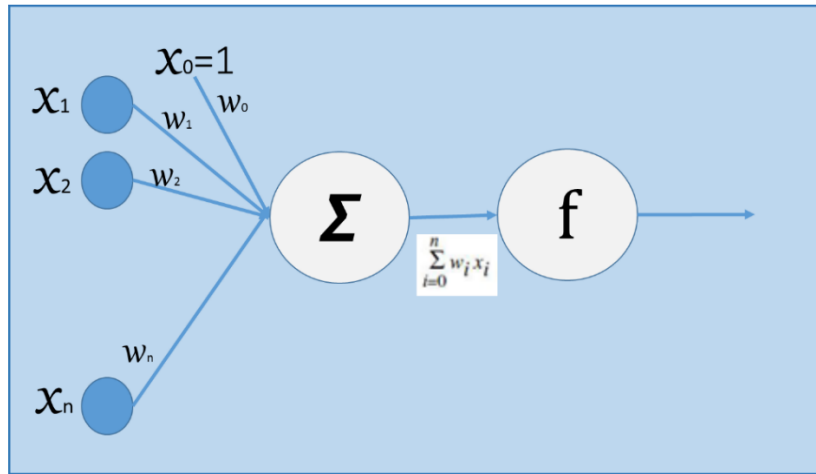


Figura 3.4: Representação gráfica de um perceptrão genérico.

Geralmente utiliza-se uma função designada por sigmoide e que é dada por:

$$\text{sigmoide}(\beta x) = \frac{1}{1+e^{-\beta x}} \quad (\text{Eq. 3.2})$$

Também é vastamente utilizada a função tanh (tangente hiperbólica), dada por:

$$\text{tanh}(\beta x) = \frac{e^{\beta x} - e^{-\beta x}}{e^{\beta x} + e^{-\beta x}} \quad (\text{Eq. 3.3})$$

onde:

$\beta$  – é o coeficiente que controla a derivada e a amplitude da função

$x$  – é o parâmetro de entrada

Deste modo é compreensível que o funcionamento do perceptrão consiste no somatório de todas as entradas multiplicadas por pesos, de forma individual, e cujo resultado é aplicado a uma função previamente definida.

### **Treino do *Perceptrão***

Após esclarecer o modo de funcionamento do perceptrão, deve-se perceber porque é que o treino do perceptrão é importante e fundamental. O conceito da rede neuronal está inerente ao facto de ser necessário aplicar valores de entrada para se ter valores de saída, tal como na aprendizagem cognitiva é necessário passar por experiências, assimilar conhecimento para depois poder fazer uso desse conhecimento de forma coerente e consistente.

O treino do perceptrão emula a mudança de estado de um neurónio aquando a aprendizagem, ou seja, quando se aprende algo os neurónios associados a esse conhecimento alteram o seu estado de forma a comportar esse mesmo conhecimento e reagir em conformidade.

É importante definir neste contexto dois conceitos que vão acompanhar toda a teoria das redes neuronais explicadas aqui.

O primeiro conceito a definir é o de conjunto de treino. Este conjunto permite que se aplique valores na entrada e que se compare os valores de saída com os valores esperados. Essa diferença será o erro induzido pela rede neuronal, e esse erro será utilizado para atualizar os pesos de forma a minimizar esse mesmo erro.

O segundo conceito a definir é o de conjunto teste ou avaliação. Este conjunto serve para determinar o desempenho da rede neuronal após o treino, ou seja, ao aplicar os valores do conjunto teste à rede neuronal qual o erro que se deve esperar nos valores de saída, uma vez que também o conjunto teste tem os valores reais de saída.

É ainda importante referir que o conjunto treino e o conjunto teste devem ser gerados pela mesma função distribuição, ou seja que tenham as mesmas características. Por isso usualmente para se treinar uma rede neuronal e medir o seu desempenho retira-se uma amostragem aleatória, designada por conjunto teste, e depois de treinada a rede neuronal com o conjunto treino, serve-se do conjunto teste para medir o desempenho.

As fórmulas matemáticas seguintes são as utilizadas para treino do perceptrão:

$$w_i = w_i + \Delta w_i \quad (\text{Eq. 3.4})$$

$$\Delta w_i = \eta(t - s)x_i \quad (\text{Eq. 3.5})$$

onde:

$\eta$  – Taxa de aprendizagem (constante > 0)

$t$  – Valor esperado na saída

$s$  – Valor gerado pela função de avaliação (saída)

$x_i$  – Valor na entrada  $i$

Note-se que  $(t-s)$  é o erro, ou seja a diferença entre o valor esperado e o valor gerado. Este erro multiplicado pela taxa de aprendizagem e pelo valor de entrada revela o valor pelo qual o peso é atualizado. Se o erro for zero não existe atualização do peso. Existe atualização de pesos até se obter o resultado desejado ou, no caso de função de avaliação contínua, um erro  $\leq \epsilon$  previamente definido.

Exemplo:

Se o perceptrão só tiver uma entrada  $x_1$  e esta tiver o valor 4 e o valor esperado de saída for -1, mas o valor gerado de saída for 1 para o perceptrão binário, sendo  $\eta=0.2$ ,  $w_0=2$  e  $w_1=3$  temos:

Início:

$$s(4) \Rightarrow 2 + 3 * 4 = 14 > 0 \text{ logo } s(4) = 1$$

Iteração 1:

$$\Delta w_0 = 0.2 * (-1 - 1) * 4 \Rightarrow \Delta w_0 = -1.6 \Rightarrow w_0 = 2 - 1.6 = 0.4$$

$$\Delta w_1 = 0.2 * (-1 - 1) * 4 \Rightarrow \Delta w_1 = -1.6 \Rightarrow w_1 = 3 - 1.6 = 1.4$$

$$s(4) \Rightarrow 0.4 + 1.4 * 4 = 6 > 0 \text{ logo } s(4) = 1$$

Iteração 2:

$$\Delta w_0 = 0.2 * (-1 - 1) * 4 \Rightarrow \Delta w_0 = -1.6 \Rightarrow w_0 = 0.4 - 1.6 = -1.2$$

$$\Delta w_1 = 0.2 * (-1 - 1) * 4 \Rightarrow \Delta w_1 = -1.6 \Rightarrow w_1 = 1.4 - 1.6 = -0.2$$

$$s(4) \Rightarrow -1.2 - 0.2 * 4 = -2 < 0 \text{ logo } s(4) = -1$$

Iteração 3:

$$\Delta w_0 = 0.2 * (-1 + 1) * 4 \Rightarrow \Delta w_0 = 0$$

$$\Delta w_1 = 0.2 * (-1 + 1) * 4 \Rightarrow \Delta w_1 = 0$$

Logo tem-se o resultado esperado, não existe erro e, por conseguinte, não existe atualização de peso.

### Rede Neuronal Camada Simples

Após a explicação do funcionamento do perceptrão e do método de treino do mesmo, existe necessidade de compreender como funciona a interligação de perceptrões para formar uma rede neuronal. Sendo que o exemplo mais simples é uma rede neuronal de camada simples.




Figura 3.5: Rede neuronal de camada simples

A rede neuronal de camada simples apresenta vários perceptrões que não comunicam entre si. A vantagem deste tipo de redes é que aos invés de apenas poder representar um modelo baseado numa função  $f: \mathbb{R}^n \rightarrow \mathbb{R}$ , temos possibilidade de modelar uma função  $f: \mathbb{R}^n \rightarrow \mathbb{R}^n$ , o que permite com os mesmos parâmetros de entrada ter várias avaliações de saída. Se existir necessidade podem ser



atribuídos pesos ( $w_{iu}$ ) igual a zero para anular o efeito de uma entrada ( $x_i$ ) em determinado perceptrão  $j$ .

O treino dos perceptrões da rede neuronal de camada simples assemelha-se ao treino para perceptrões simples, uma vez que cada perceptrão é independente dos outros, tal como os seus pesos.

### Redes Neurais Multicamada

Com a utilização de redes multicamadas potencia-se o uso das redes neuronais. É através desta fórmula de utilização que se gera o poder real de aprendizagem inerente às redes neuronais e que permitem uma aplicação quase na generalidade das ferramentas que necessitam de uma componente de adaptação cognitiva através da experiência.

A rede neuronal multicamada consiste numa primeira camada que recebe os valores de entrada, em uma ou várias camadas designadas por camadas escondidas e numa última camada que gera os valores de saída da rede. Cada um dos perceptrões da primeira camada comunica com os perceptrões da 2ª camada, os da 2ª camada comunicam com os da 3ª camada, e assim sucessivamente.




Figura 3.6: Rede neuronal multicamada

O cálculo dos valores para a rede neuronal multicamada ter-se-ia:

$$s_{ij} = f(y_{ij}) \quad (\text{Eq. 3.6})$$

Onde:

$s_{ij}$  é a saída da função de avaliação do perceptrão  $ij$ , perceptrão  $j$  da camada  $i$ .

$f$  é a função avaliação (exemplo: sigmoide)

e  $y_{ij}$  parâmetro de entrada da função  $f$  é definida como:

Caso o perceptrão pertença à primeira camada

$$y_{0j} = w_{0j} + \sum_i w_{ij}x_i \quad (\text{Eq. 3.7})$$

Caso o perceptrão não pertença à primeira camada

$$y_{ij} = w_{i0} + \sum_j w_{ij}s_{(i-1)j} \quad (\text{Eq. 3.8})$$

Onde  $i-1$  é camada anterior

Quanto mais camadas e perceptrões tiver a rede neuronal maior deverá ser a sua capacidade de aprendizagem. As redes neuronais multicamada permitiram alguns avanços tecnológicos a nível computacional, nomeadamente no reconhecimento de padrões que permitem que o sistema reaja mediante os resultados da análise do conhecimento e aprendizagem.

### Algoritmo de Retropropagação

Um dos problemas associados às redes neuronais multicamadas foi a estimação de parâmetros associados aos perceptrões. O algoritmo de retropropagação foi desenvolvido com intuito das redes neuronais multicamadas poderem ser treinadas. Este método está associado à minimização do risco empírico, em que é criada uma rede neuronal auxiliar nova obtida por transposição da rede neuronal original [77, p. 173].

O algoritmo de retropropagação é definido da seguinte forma:

- 1) Inicialização dos pesos: os pesos devem ser inicializados com valores aleatórios pequenos;  $t=1$
- 2) Cálculo das variáveis para cada conjunto de dados do conjunto de treino:

Perceptrão:

$$s_j = \sum_i w_{ij}x_i + w_{0j} \text{ primeira camada} \quad (\text{Eq. 3.9})$$

$$s_j = \sum_i w_{ij}y_i + w_{0j} \text{ camadas seguintes} \quad (\text{Eq. 3.10})$$

com i e camada anterior

$$y_i = f(s_j)$$

Rede de retropropagação:

$$\varepsilon_j = f'(s_j) \frac{\partial c}{\partial y_j} \text{ camada de saída} \quad (\text{Eq. 3.11})$$

$$\varepsilon_j = f'(s_j) \sum_p w_{jp} \text{ camadas anteriores} \quad (\text{Eq. 3.12})$$

3) Atualização dos pesos

$$w_{ij}(t) = w_{ij}(t-1) + \Delta w_{ij} \quad (\text{Eq. 3.13})$$

$$\Delta w_{ij} = -\frac{\alpha}{N} \sum_{x \in X} x_i \varepsilon_i \text{ primeira camada} \quad (\text{Eq. 3.14})$$

$$\Delta w_{ij} = -\frac{\alpha}{N} \sum_{x \in X} y_i \varepsilon_i \text{ camadas seguintes} \quad (\text{Eq. 3.15})$$

4) Incrementar t e voltar ao ponto 2 até existir uma condição de paragem.

Para uma função ativação  $f(\beta x) = \text{sigmoide}(\beta x)$ :

$$f'(\beta x) = \frac{\beta e^{\beta x}}{(e^{\beta x} + 1)^2} \quad (\text{Eq. 3.16})$$

Sendo as funções  $f(x)$  (azul) e  $f'(x)$  (vermelho), com  $\beta=1$ , estão representadas na Figura 3.7:




Figura 3.7: Representação gráfica de  $f(x)$  e  $f'(x)$  para  $f(x) = \text{sigmoide}(x)$

Para uma função ativação  $f(\beta x) = \tanh(\beta x)$ :

$$f'(\beta x) = \frac{4\beta e^{2\beta x}}{(e^{2\beta x} + 1)^2} \quad (\text{Eq. 3.17})$$

Sendo as funções  $f(x)$  (azul) e  $f'(x)$  (vermelho), com  $\beta=1$ , estão representadas na Figura 3.8:




Figura 3.8: Representação gráfica de  $f(x)$  e  $f'(x)$  para  $f(x) = \tanh(x)$

### Modelação por Redes Neurais

A modelação matemática de um certo ambiente permite que através de uma função, simples ou complexa, se recrie os estados finais (saída) a partir dos dados de entrada. Isto significa que a modelação de um certo ambiente permite simular os resultados das ações induzidas nesse mesmo ambiente. O desempenho de um modelo difere conforme a dificuldade de modelação, assim como a adequação das técnicas utilizadas para criar o modelo.

Ambientes complexos, com muitas variáveis, podem ser de difícil, ou mesmo impossível, modelação. Quanto maior for o número de variáveis intrínsecas a um ambiente mais difícil será identificar cada uma dessas variáveis, o que pode levar a modelos que não se comportam como o ambiente original.

As redes neurais representam um método de aprendizagem bem-sucedido no que toca a dados com ruído ou dados complexos. São apropriadas para problemas que tenham as seguintes características [79, pp. 83-85]:

- a) Problemas que são representados por pares de vários atributos: Problemas que requerem uma função de avaliação que tenha várias saídas/resultados. As redes

neurais podem avaliar os dados de entrada e dar como resultado um conjunto de saídas predefinidas.

- b) A função alvo tem como resultado valores reais, discretos ou conjuntos de valores reais ou discretos: A função de avaliação é uma função matemática que representa o ambiente que se pretende modelar, os dados de entrada representam ações que interagem com o ambiente e os resultados são valores reais ou discretos ou um conjunto composto por valores reais ou discretos. Externamente esses valores podem representar outro tipo de dados, por exemplo numa determinada saída o valor 1 pode representar “leite”, o valor 2 pode representar “farinha”, o valor 3 pode representar “água”, ou seja, a rede neuronal dará na saída valores discretos, mas a sua representação externa poderá ter outro significado.
- c) Os conjuntos de treino podem conter erros ou ruído: Os conjuntos de dados utilizados para treinar a rede neuronal poderá ter informação que não corresponde a um estado totalmente aceite pelo ambiente. Isto significa que o treino da rede neuronal não está restrito a dados com uma distribuição definida.
- d) Períodos de tempo longos para treino da rede neuronal: A possibilidade de treinar a rede neuronal por longos períodos, permite que se utilize redes neurais complexas ou conjuntos de treinos com grande dimensão. Na realidade após a rede neuronal estar treinada os valores inerentes a essa rede neuronal mantem-se inalterados.
- e) Requerido um período de avaliação curto: Depois da rede neuronal estar treinada esta pode ser representada por uma função matemática de acordo com a complexidade da rede neuronal. Esta função matemática deverá ser, em princípio, de uma rápida avaliação. Ou seja, o cálculo dos resultados, a partir dos dados de entrada, deverá ser executado num período de tempo curto.
- f) Não seja importante a compreensão da função de avaliação: A rede neuronal treinada corresponde a uma função matemática. A compreensão dessa função não é importante para a utilização da rede neuronal, apesar disso a interligação dos neurónios torna difícil uma compreensão exaustiva da função matemática resultante.

Um exemplo das potencialidades de modelação por redes neuronal está descrito no artigo de Chong, Abbas, Flintsch e Higgs(2012), cuja experiência consistiu modelar partes do comportamento de um condutor de automóvel no meio do trânsito. A experiência permitiu concluir que as redes neuronais permitem uma modelagem do comportamento aproximada à realidade [80].

Badea(2014) refere no seu artigo, dedicado ao estudo de previsão comportamental dos consumidores através de redes neuronais, que apesar do conjunto treino ser algo limitado, as redes neuronais mostraram bons resultados na modelação e por isso conclui que é uma boa escolha para melhorar estratégias de marketing e processos de decisão [81, p. 245].

## 3.2 Metodologia de Redes Neuronais aplicadas no estudo

### 3.2.1 Metodologia

A análise inerente ao estudo proposto está baseada na utilização de duas plataformas, para criação dos modelos estratégicos através de RNAs, a plataforma R (CRAN) e a Net Console (Sony). Estas plataformas têm uma larga utilização no mundo académico. Para se chegar a conclusões mais fidedignas utilizou-se as duas plataformas para se gerar os modelos e analisou-se os resultados obtidos.

A criação dos modelos utiliza os dados obtidos através dos inquéritos aos gestores onde cada uma das questões representa uma entrada da rede neuronal, sendo 11 entradas no total. A saída da rede neuronal identifica qual deve ser o rácio expectável entre os resultados financeiros anteriores e os resultados financeiros a serem considerados.

O modelo será avaliado através dos resultados obtidos numa vertente de valores previstos versus valores reais. Será analisado os erros induzidos pelos modelos, assim como o comportamento do modelo face aos valores de entrada. O comportamento do modelo será avaliado de uma forma mais visual possibilitado pelos gráficos gerados pelos valores previstos. Os métodos utilizados para interpretar os resultados estão descritos na secção 4.3.

Os erros serão analisados de forma a avaliar duas componentes, a primeiro é o erro relativo médio e a segunda é o número de amostras que se enquadram em cada uma das categorias de erro definidas. Desta forma é possível avaliar com mais precisão o comportamento do modelo em relação ao seu desempenho.

Face aos pressupostos considerar-se-á erros médios relativos abaixo dos 25% e modelos com pelo menos 70% das amostras com valores previstos com um erro relativo inferior a 30% como indicadores de uma boa modelação.

É preciso descrever alguns conceitos associados às plataformas (R CRAN e NetConsole) utilizadas para criar os modelos que servem para testar a hipótese A.

A Neural Net Console da Sony ([dl.sony.com](http://dl.sony.com)) permite a definição muito específica da rede neuronal a utilizar através de módulos previamente definidos na aplicação. Para cada camada da rede neuronal pode ser definida especificamente qual o algoritmo a utilizar. Podem ser utilizados módulos de multiplicação de saídas e entradas de cada camada, assim como funções de ativação diferentes para cada camada. A Neural Network Console tem capacidades de ‘Deep Learning’.

A Neural Network Console permite ainda que seja procurada de forma automática a melhor rede neuronal para modelar o ambiente desejado. Esta funcionalidade não foi utilizada neste estudo, mas existiu uma procura através de experiências feitas para produzir resultados aceitáveis. Após a definição desta rede neuronal, esta foi utilizada para modelar todos os ambientes de forma a que torne o estudo mais fiável e independente de um modelo criado especificamente para obter os melhores resultados.

Por outro lado, a plataforma R não permite a mesma flexibilidade da Neural Network Console, mas permite a automatização das experiências de forma mais fácil, uma vez que é baseada numa linguagem de programação própria do R e das bibliotecas utilizadas (`readxl`; `dplyr`, `neuralnet`).

A biblioteca `NeuralNet` da plataforma R, tem predefinidos algoritmos para treino das redes neuronais, sendo que os algoritmos utilizados neste estudo foram o `RProp+`, `RProp-` e `SAG`. A automatização permitiu a definição de algoritmos extra que utilizam os algoritmos referidos. Os algoritmos desenvolvidos foram:

- 1) `RProp Avg` : que consiste na utilização dos algoritmos `RProp+` e `RProp-` e utilizar a sua média para providenciar os valores previstos
- 2) `*/Q` : que consiste na utilização dos algoritmos referidos (`RProp+`; `RProp-` e `SAG`) mas onde as entradas são normalizadas pela soma absoluta das respostas do questionário individual de cada um dos gestores (`RProp+/Q`; `RProp-/Q` e `SAG/Q`). Descrito na secção 4.2.4 em “Normalização de Respostas ao Questionário”.

- 3) AVG6: que consiste na média dos algoritmos referidos (RProp-, Rpro+ e SAG) e na sua forma de normalização pelo resultado da soma absoluta do questionário individual de cada um dos gestores ( $*/Q$ ).

Isto significa a utilização de 8 algoritmos para cada modelo e no qual se analisa cada um individualmente. A modelação pode não ser bem conseguida em todos devido à especificidade do modelo, mas obtenção de alguns bons modelos permite chegar a uma conclusão sobre a possibilidade de modelação.

O estudo é baseado em experiências e a conclusão baseada nos resultados dessas experiências. A conclusão é baseada sobretudo no erro entre os valores previstos e os valores reais e numa base estatística predefinida, isto é não se espera que o modelo consiga prever com exatidão, mas o sucesso depende do desempenho do modelo. Cada uma das experiências é replicável utilizando quer os mesmos dados quer os modelos criados.

Por último deve-se salientar que embora tenham existido experiências para definir a topologia da rede neuronal que possibilitasse uma modelação do ambiente desejado, não existiu uma manipulação para que a rede neuronal desse os resultados desejados. Isto é as experiências descritas utilizam a mesma topologia e os dados, quer de treino quer de teste, foram definidos de forma aleatória e não escolhidos de forma a dar os resultados que possibilitassem uma conclusão positiva.

### 3.2.2 Algoritmos Utilizados no Estudo

#### ***RProp***

O algoritmo RProp vem do nome Retro**prop**agação **Resiliente** (Resilient Backpropagation). É um algoritmo que assenta no princípio da eliminação da influência do valor da derivada parcial em relação ao peso da ligação entre perceptrões. Sendo que se enquadra na categoria dos algoritmos de aprendizagem adaptativa local [82].

No algoritmo de aprendizagem RProp o sinal de cada atualização do peso é baseado na derivada parcial  $\partial E / \partial w_{ij}$ . A atualização dos pesos é feita individualmente para cada peso. Sendo que  $w_{ij}$ , significa o peso que liga o perceptrão  $i$  ao perceptrão  $j$  e  $E$  a função de cálculo do erro. Para cada peso  $w_{ij}$  é calculado um  $\Delta_{ij}$  ajustado utilizando a seguinte regra [83]:



$$\Delta_{ij}^{(t)} = \begin{cases} \eta^+ \cdot \Delta_{ij}^{(t-1)}, & \text{se } \frac{\partial E^{(t-1)}}{\partial w_{ij}} \cdot \frac{\partial E^{(t)}}{\partial w_{ij}} > 0 \\ \eta^- \cdot \Delta_{ij}^{(t-1)}, & \text{se } \frac{\partial E^{(t-1)}}{\partial w_{ij}} \cdot \frac{\partial E^{(t)}}{\partial w_{ij}} < 0 \\ \Delta_{ij}^{(t-1)}, & \text{caso contrário} \end{cases} \quad (\text{Eq. 3.18})$$

Onde  $0 < \eta^- < 1 < \eta^+$ , assim se a derivada parcial  $\partial E / \partial w_{ij}$  tiver o mesmo sinal durante duas iterações seguidas o  $\Delta_{ij}^{(t)}$  aumenta, se mudar de sinal em duas iterações seguidas o  $\Delta_{ij}^{(t)}$  diminui.. Pode existir um mínimo e um máximo para  $\Delta_{ij}^{(t)}$ .

Esta é a forma como se calcula o valor de atualização dos pesos, a forma com se atualiza os pesos ( $w_{ij}$ ) da rede identifica se se utiliza o algoritmo RProp+ (o algoritmo original RProp) ou o algoritmo RProp- (variante melhorada do algoritmo RProp).

#### **RProp+**

Para o algoritmo RProp+ atualização dos pesos é feita mediante as seguintes regras [83]:

Se  $\frac{\partial E^{(t-1)}}{\partial w_{ij}} \cdot \frac{\partial E^{(t)}}{\partial w_{ij}} > 0$  então

$$\Delta w_{ij}^{(t)} = -\text{sinal} \left( \frac{\partial E^{(t)}}{\partial w_{ij}} \right) \cdot \Delta_{ij}^{(t)} \quad (\text{Eq. 3.19})$$

Se  $\frac{\partial E^{(t-1)}}{\partial w_{ij}} \cdot \frac{\partial E^{(t)}}{\partial w_{ij}} < 0$  então

$$\Delta w_{ij}^{(t)} = -\Delta w_{ij}^{(t-1)} \quad \text{e} \quad \frac{\partial E^{(t)}}{\partial w_{ij}} = 0 \quad (\text{Eq. 3.20})$$

A atualização dos pesos propriamente dita:

$$w_{ij}^{(t+1)} = w_{ij}^{(t)} + \Delta w_{ij}^{(t)} \quad (\text{Eq. 3.21})$$

Desta forma pode-se dizer que o sinal + na nomenclatura do algoritmo significa a utilização do peso prévio (*weight-backtracking*).

**RProp-**

Por sua vez o algoritmo RProp-, em qualquer dos casos, utiliza a fórmula:

$$\Delta w_{ij}^{(t)} = -\text{sign}\left(\frac{\partial E^{(t)}}{\partial w_{ij}}\right) \cdot \Delta_{ij}^{(t)} \quad (\text{Eq. 3.22})$$

Sendo que a atualização dos pesos é:

$$w_{ij}^{(t+1)} = w_{ij}^{(t)} + \Delta w_{ij}^{(t)} \quad (\text{Eq. 3.23})$$

Basicamente o algoritmo RProp-, não utiliza o peso prévio (sem *weight-backtracking*), sendo que a atualização dos pesos é sempre feita.

**SAG**

O algoritmo SAG designa o algoritmo de Menor Derivada Absoluta (Smallest Absolute Derivative), faz parte de um grupo de algoritmos pertencentes à categoria GRProp. Os algoritmos GRProp, que vem de Variantes Globalmente Convergentes do RProp (Globally convergent modification of RPROP), são criados a partir de bases teóricas matemáticas. Este tipo de algoritmos tem um importante aumento no desempenho em relação aos algoritmos tradicionais RProp, conseguindo aplicar novas estratégias de taxas de aprendizagem e a aprendizagem é induzida por uma procura de mínimos globais ao invés de mínimos locais [84], apesar de existirem exceções [85]. A implementação utilizada no estudo empírico (NeuralNet R CRAN) evita direções inapropriadas na atualização dos pesos, mas tendo algum impacto no desempenho de processamento da rede [85].

### 3.2.3 Topologia e Parametrização

#### *Neural Network Console*

A topologia e módulos utilizados para a rede neuronal na plataforma Neural Network Console pode ser visualizada na Figura 3.9.

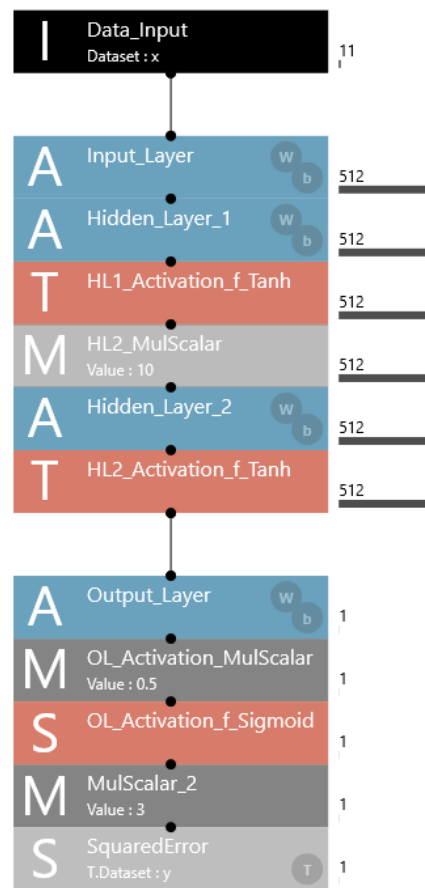


Figura 3.9: Topologia da RNA utilizada na Neural Network Console

Sendo que o modo de processamento pode ser descrito como:

- 1) Data Input: Os dados do modelo são introduzidos a partir deste modulo. Pode verificar-se que se define como um vetor com 11 parâmetros.
- 2) Input Layer: A primeira camada consiste em 11 entradas (perceptrões) e cada um dos perceptrões tem 512 ligações de saída.
- 3) Hidden Layer 1: A primeira camada escondida é constituída por 512 perceptrões.
- 4) HL1 Activation Function: A função de ativação da primeira camada é definida como a função Tanh (Tangente Hiperbólica).
- 5) HL1 MultScalar: Os resultados provenientes da primeira camada escondida (após a função de ativação) são multiplicados por 10.

- 6) Hidden Layer 2: A segunda camada escondida é constituída por 512 perceptrões
- 7) HL2 Activation Function: A função ativação da segunda camada escondida é definida como a função Tanh
- 8) Output Layer: A última camada (camada de saída) da RNA recebe um vetor de 512 parâmetros e tem apenas 1 perceptrão.
- 9) OL Activation Multiscalar: O valor que será passado para a função ativação será multiplicado por 0.5
- 10) OL Activation Function: A função ativação da última camada é definida como a função sigmoide.
- 11) MultiScalar: O valor proveniente da última camada (após função ativação) é multiplicado por 3
- 12) Squared Error: A função de avaliação do erro, que vai gerar o treino da rede, é a função de erro quadrático.

### **R CRAN**

Para modelos gerados a partir da plataforma R CRAN a topologia das Redes Neurais terá a arquitetura (11,256,256,128,32,1) pelo que terá a seguinte disposição:

- 1) Camada de entrada: É constituída por 11 perceptrões, 1 perceptrão por cada entrada.
- 2) Primeira camada escondida: É constituída por 256 perceptrões.
- 3) Segunda camada escondida: É constituída por 256 perceptrões.
- 4) Terceira camada escondida: É constituída por 128 perceptrões.
- 5) Quarta camada escondida: É constituída por 32 perceptrões.
- 6) Camada de saída: É constituída por 1 perceptrão.
- 7) Em todas as camadas a função de ativação será a função logística sigmoide
- 8) A Função de avaliação do erro é a função de erro quadrático.

Note-se que na definição da topologia da plataforma do R CRAN apenas é definido o núcleo de camadas escondidas. A camada de entrada é definida automaticamente consoante o comprimento do vetor de entrada, assim como a camada de saída é definida automaticamente a partir do comprimento do vetor dos componentes de saída das amostras do conjunto de treino.

Foram utilizados os seguintes parâmetros na definição das redes neuronais:

- 1) learningrate = 0.9
- 2) linear.output = TRUE
- 3) threshold = 0.03

O valor do número máximo de iterações (*stepmax*) para o treino da rede foi definido consoante o algoritmo a ser utilizado e o modelo a ser criado:

1) Modelos ME13, ME14, ME15, ME13T14, ME14T15

- a. RProp- : 300
- b. RProp+ : 300
- c. SAG : 300
- d. RProp-/Q : 300
- e. RProp+/Q : 300
- f. SAG/Q : 300
- g. RProp Avg
  - i. RProp- : 250000
  - ii. RProp+ : 250000
- h. AVG6
  - i. RProp- : 500
  - ii. RProp+ : 500
  - iii. SAG : 500
  - iv. RProp-/Q : 500
  - v. RProp+/Q : 500
  - vi. SAG/Q : 500

2) Modelo MEGlobal

- a. RProp- : 250000
- b. RProp+ : 250000
- c. SAG : 250000
- d. RProp-/Q : 250000
- e. RProp+/Q : 250000
- f. SAG/Q : 250000
- g. RProp Avg
  - i. RProp- : 250000
  - ii. RProp+ : 250000
- h. AVG6
  - i. RProp- : 300
  - ii. RProp+ : 300
  - iii. SAG : 300
  - iv. RProp-/Q : 2000
  - v. RProp+/Q : 2000
  - vi. SAG/Q : 2000

O parâmetro stepmax serve para limitar a procura pela otimização da rede neuronal. Não tem uma influência direta no desempenho da rede neuronal a não ser que o número máximo de iterações definido não seja suficiente para alcançar o ponto ótimo, o que pode depender da complexidade do ambiente a ser modelado.

### 3.3 Árvores de Decisão

Nesta secção irá ser explicado o conceito e o modo de funcionamento das árvores de decisão. Esta metodologia foi utilizada como comparativa no desempenho das RNAs. Fazendo parte da metodologia utilizada para modelar os ambientes estratégicos necessários para fazer prova da hipótese, julga-se ser necessário descrever o conceito e o seu funcionamento. Nestas descrições tentou-se ser o mais conciso e claro possível sem entrar em aprofundamentos da matéria, providenciando um conhecimento acessível a todos. Julga-se que o conhecimento aqui transcrito é o suficiente para compreender como as experiências do estudo empírico foram executadas na vertente das Árvores de Decisão.

#### *Conceito*

As árvores de decisão estão incluídas nas metodologias inerentes à aprendizagem supervisionada e são amplamente utilizadas em problemas de classificação. É necessário um conjunto treino que define a geração do modelo desejado. As árvores de decisão podem ser utilizadas para gerar modelos com valores de entrada e saída contínuos e também discretos. Nesta tese considerou-se modelos com valores de saída discretos e por isso a necessidade de transformação da relação dos valores financeiros em categorias.

Uma árvore de decisão funciona como um sistema de caminhos possíveis, onde cada caminho representa um parâmetro de entrada numa função previamente concebida. Da perspetiva que considera uma AD como um sistema de decisão, é possível visualizar o caminho a percorrer até uma folha de forma a prever o resultado. O inverso, percorrer uma determinada folha até ao nó raiz, permite a escolha das melhores opções para alcançar o objetivo.

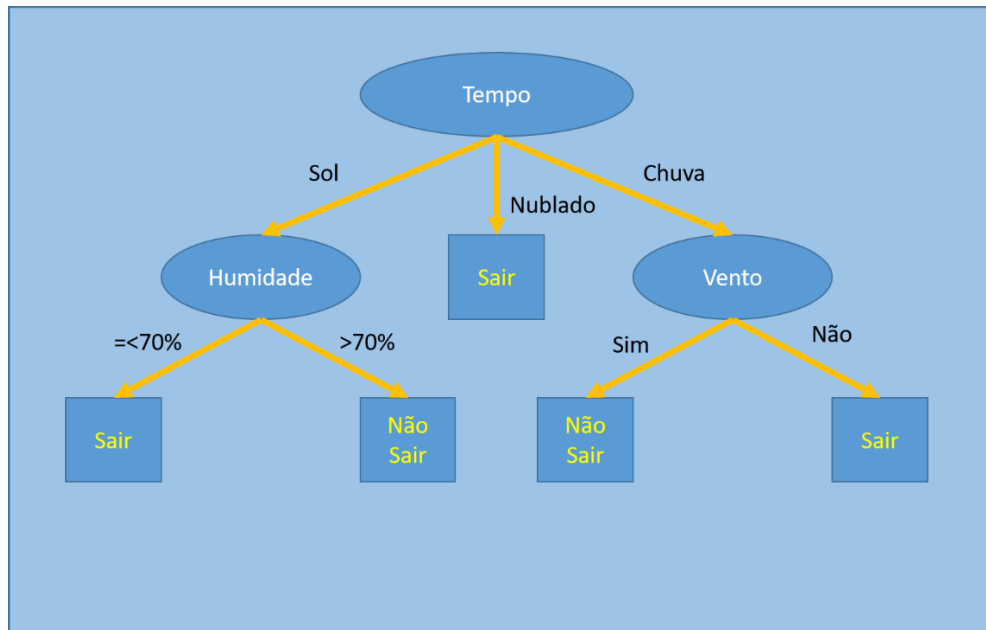


Figura 3.10 – Exemplo de Árvore de Decisão

De forma a perceber melhor, a árvore de decisão pode funcionar como um mapa que permite escolher os caminhos até ao destino, ou através de um conjunto de indicações permite verificar qual o destino final.

Na árvore de decisão da Figura 3.10, pode-se verificar um sistema que permite chegar a uma decisão quanto a sair ou não conforme as condições atmosféricas. Pode verificar-se que existem 3 condições que aconselham o indivíduo a sair: Se estiver sol e a humidade do ar for inferior a 70%, se estiver apenas nublado (nem sol, nem chuva) ou se estiver chuva, mas não vento. Todas as outras alternativas indicam um aconselhamento de não sair. Este é apenas um simples exemplo para permitir visualizar o funcionamento de um sistema de apoio à decisão baseado numa árvore de decisão.

Uma das grandes vantagens das árvores de decisão é que é fácil compreender as razões que regeram a escolha de determinado caminho. A fácil visualização do caminho escolhido em detrimento de outros caminhos possíveis permite uma fácil interpretação dos motivos que levaram a determinado resultado.

### ***Modo de funcionamento***

As árvores de decisão podem servir para modelar ambientes com dois tipos de comportamento: decisões ou previsões cujo os valores são discretos ou decisões ou previsões cujos valores são contínuos. Existem algoritmos para criar as árvores de decisão com qualquer um destes comportamentos. Nesta tese de doutoramento apenas serão utilizadas árvores de decisão cuja modelação está associada a um comportamento que infere valores discretos, ou também conhecida por categorização. Desta forma a descrição do funcionamento focar-se-á na construção de ADs de categorização.

Para entender o funcionamento de geração de uma árvore de decisão é necessário compreender o significado de cada componente inerentes às árvores de decisão:

- 1) Nó raiz: o nó raiz é o ponto inicial de uma árvore. É a partir deste nó que começa a separação de caminhos possíveis.
- 2) Nós interno (ou de decisão): Cada nó interno representa um ponto de decisão, baseado numa variável de decisão, que permite escolher um caminho a seguir.
- 3) Nó folha (ou terminal): Os nós folhas indicam uma decisão final para o caminho percorrido até então.
- 4) Ramos (ou ligações nodais): Cada ramo representa a ligação entre os nós (de decisão ou terminal) correspondente a cada escolha possível pelo

Existem ainda algoritmos para a geração de árvores de decisão que comportam nós probabilísticos que ao invés de resultarem numa única decisão induzem uma probabilidade do acontecimento associado ao nó seguinte. Este tipo de árvore representa um modelo de ambiente probabilístico ao invés de um modelo de ambiente previsional, que não está dentro do âmbito desta tese.






Figura 3.11- Exemplo de uma árvore de decisão probabilística

A Figura 3.11 representa uma árvore de decisão induzida por um modelo probabilístico de dois lançamentos consecutivos de uma moeda. Este tipo de árvore pode ser utilizado por exemplo para calcular valores médios esperados do lucro de um negócio mediante a parametrização do ambiente económico, mas os resultados não induzem situações determinísticas e por isso não induzem a possibilidade de uma previsão.

Para compreender a geração de uma árvore de decisão é necessário compreender dois conceitos de avaliação e escolha dos nós, a entropia e o ganho de informação. Os dois conceitos estão relacionados entre si. A entropia é uma medida que caracteriza a aleatoriedade ou impureza de uma coleção arbitrária de exemplos. Calculada pela seguinte formula:

$$Entropia(S) = - \sum p(x).log_2(p(x)) \quad (Eq. 3.24)$$

Onde:

$P^+$  é a proporção de exemplos positivos em S.

$p^-$  é a proporção de exemplos negativos em S.

A função Entropia tem uma representação gráfica da forma:




Figura 3.12- Representação gráfica da função Entropia(S) vs p

Na geração da árvore de decisão interessa diminuir a entropia, ou seja, a aleatoriedade da variável que define as classes.

Por sua vez o ganho de informação é a redução esperada na entropia causada pela criação da partição dos exemplos de acordo com o teste executado. E pode ser calculado pela seguinte formula:

$$Ganho(S,A) = Entropia(S) - \sum_{v \in Valores(A)} \left( \frac{|S_v|}{|S|} Entropia(S_v) \right) \quad (Eq. 3.25)$$

Por exemplo, para os dados que deram origem á árvore de decisão representada na Figura 3.10,

Amostra	Tempo	Temperatura	Humidade	Vento	Sair?
1	Sol	Alta	Media	Não	Não
2	Sol	Alta	Alta	Sim	Não
3	Nublado	Alta	Alta	Não	Sim
4	Chuva	Baixa	Alta	Não	Sim
5	Chuva	Baixa	Média	Não	Sim
6	Chuva	Baixa	Baixa	Sim	Não
7	Nublado	Baixa	Baixa	Sim	Sim
8	Sol	Média	Alta	Não	Não
9	Sol	Baixa	Baixa	Não	Sim
10	Chuva	Média	Média	Não	Sim
11	Sol	Média	Baixa	Sim	Sim
12	Nublado	Média	Alta	Sim	Sim
13	Nublado	Alta	Baixa	Não	Sim
14	Chuva	Baixa	Alta	Sim	Não

Tabela 3-1: Dados de origem da árvore de decisão representada na Figura 3.10

A entropia dos dados da Tabela 3-1 pode ser calculada da seguinte forma:

$$Entropia([9 + ,5 -]) = -(\frac{9}{14} \cdot \log_2(\frac{9}{14}) + \frac{5}{14} \cdot \log_2(\frac{5}{14})) = 0.940$$

Uma vez que existem 9 amostras com resultado positivo e 5 amostras com resultado negativo, de um total de 14 amostras. Para calcular o Ganho de Informação inerente ao atributo Tempo=Sol tem-se:

- $p(\text{sim sair}|\text{tempo=sol}) = 2/5$
- $p(\text{não sair}|\text{tempo=sol}) = 3/5$
- $Entropia(\text{sair}|\text{tempo=sol}) = -(2/5) \cdot \log_2(2/5) - (3/5) \cdot \log_2(3/5) = 0.971$

Para o atributo Tempo=Nublado tem-se:

- $p(\text{sim sair}|\text{tempo=nublado}) = 1$ , todas as opções para tempo nublado tem o resultado de sair
- $p(\text{não sair}|\text{tempo=nublado}) = 0$
- $Entropia(\text{sair}|\text{tempo=nublado}) = -(4/4) \cdot \log_2(4/4) - 0 \cdot \log_2(0) = 0$

Para o atributo Tempo=Chuva tem-se:

- $p(\text{sim sair}|\text{tempo=chuva}) = 3/5$
- $p(\text{não sair}|\text{tempo=chuva}) = 2/5$
- $Entropia(\text{sair}|\text{tempo=chuva}) = -(3/5) \cdot \log_2(3/5) - (2/5) \cdot \log_2(2/5) = 0.971$

O Ganho de Informação induzida pelo atributo Tempo é calculado da seguinte forma:

- $\sum_{v \in \text{valores}(A)} (\frac{|S_v|}{|S|}) Entropia(S_v) = (5/14) \cdot 0.971 + (4/14) \cdot 0 + (5/14) \cdot 0.971 = 0.693$
- $Ganho(S, \text{tempo}) = 0.940 - 0.693 = 0.247$

O Ganho de Informação revela a sua importância na hora de decidir as ligações a formar a partir de determinado nó. Para o exemplo apresentado tem-se:

- $Ganho(S, \text{Humidade}) = 0.057$
- $Ganho(S, \text{Vento}) = 0.048$
- $Ganho(S, \text{Temperatura}) = 0.029$

- $\text{Ganho}(S, \text{Tempo}) = 0.247$

Uma vez que o Ganho de Informação é superior quando considerado o atributo tempo, o primeiro nó a ser criado será relativo às opções do tempo. As ligações a serem criadas serão 3 (três) relativas às hipóteses de escolha sol, chuva e nublado.

Na próxima iteração o atributo tempo já não será tido em consideração. Desta forma encontrar-se-á o próximo atributo a ser levado em conta para cada um dos nós de decisão. Por exemplo começar-se-á pelo nó de decisão sol onde teremos os seguintes ganhos:

- $\text{Ganho}(S_{\text{Sol}}, \text{Humidade}) = 0.971 - (3/5)*0 - (2/5)*0 = 0.971$
- $\text{Ganho}(S_{\text{Sol}}, \text{Temperatura}) = 0.971 - (2/5)*0 - (2/5)*1 - (1/5)*0 = 0.571$
- $\text{Ganho}(S_{\text{Sol}}, \text{Vento}) = 0.971 - (2/5)*1 - (3/5)*(0.018) = 0.019$

Logo, o atributo Humidade seria a escolha seguinte para o nó decisão Tempo = Sol.

O critério de paragem obedece às seguintes regras:

- Todos os exemplos pertencem à mesma classe
- Todos os exemplos têm os mesmos valores dos atributos (mas diferentes classes)
- O número de exemplos é inferior a um certo limite.
- O Ganho de todos os possíveis testes de partição dos exemplos é muito baixo.

Este método é conhecido por algoritmo ID3 e é um dos métodos mais eficientes para geração de árvores de decisão.

No entanto existe um problema associado ao critério do Ganho de Informação, uma vez que este dá preferência a atributos com muitos valores possíveis. Nestes casos ao utilizar um atributo totalmente irrelevante poderia ser criado um nó para cada valor possível. O número de nós seria igual ao número de identificadores, apesar da divisão dos nós gerar um ganho máximo, este seria totalmente inútil.

Com ruído nos dados ou excesso na procura pode acontecer o que é designado de sobre-ajustamento. O problema do sobre-ajustamento refere-se a uma resposta dada numa situação muito específica no conjunto de treino. Esta situação tende a não poder ser generalizada. No caso de um conjunto de treino com ruído a partir de uma certa profundidade as decisões tomadas são baseadas

em pequenos conjuntos de exemplos. A capacidade de agrupamento para exemplos não utilizados no crescimento da árvore diminui.

### 3.4 Metodologia das Árvores de Decisão aplicadas ao estudo

#### 3.4.1 Metodologia

A plataforma utilizada para executar os modelos é designada por R (CRAN). Esta é uma plataforma largamente utilizada pelo mundo académico e consiste numa série de bibliotecas que permitem os mais variados desenvolvimentos de aplicações matemáticas. A biblioteca utilizada para criar as árvores de decisão inerentes ao estudo é designada por ‘RPART’.

A criação dos modelos utiliza os dados obtidos através dos inquéritos aos gestores onde cada uma das questões representa possíveis nós da árvore de decisão, sendo 11 entradas no total. Os nós finais da árvore de decisão identifica qual deve ser o rácio categorizado expectável entre os resultados financeiros anteriores e os resultados financeiros a serem considerados.

O modelo será avaliado através dos resultados obtidos numa vertente de valores previstos versus valores reais. Será analisado os erros induzidos pelos modelos, assim como o comportamento do modelo face aos valores de entrada. O comportamento do modelo será avaliado de uma forma mais visual possibilitado pelos gráficos gerados pelos valores previstos. Os métodos utilizados para interpretar os resultados estão descritos na secção 4.3.

Os erros serão analisados de forma a avaliar duas componentes, a primeiro é o erro relativo médio e a segunda é o número de amostras que se enquadram em cada uma das categorias de erro definidas. Desta forma é possível avaliar com mais precisão o comportamento do modelo em relação ao seu desempenho.

Face aos pressupostos considerar-se-á erros médios relativos abaixo dos 25% e modelos com pelo menos 70% das amostras com valores previstos com um erro inferior a 30% como indicadores de uma modelação aceitável.

#### 3.4.2 Algoritmo Utilizado no Estudo (RPART)

O algoritmo para geração das árvores de decisão inerentes à criação dos modelos é o RPART (Recursive Partitioning and Regression Trees). Deste modo nesta secção irá se descrever este algoritmo. Este algoritmo é idêntico ao CART.

O algoritmo começa na raiz da árvore e define as regiões disjuntas:

$$R_1 = \{x \in R^p : X_j \leq t\} \text{ e } R_2 = \{x \in R^p : X_j > t\}$$

Utilizando os dados do conjunto de treino, faz-se a divisão dos elementos escolhendo  $\hat{j}$  e  $\hat{t}$  tais que:

$$(\hat{j}, \hat{t}) = \arg \min_{(j,t)} ((1-\hat{p}_{c1}(R_1)) + (1-\hat{p}_{c2}(R_2))) \quad (\text{Eq. 3.26})$$

Em que,

$$C_1 = \arg \max_{k=1,\dots,c} \hat{p}_k(R_1) \text{ é a classe dominante no retângulo } R_1 \quad (\text{Eq. 3.27})$$

$$C_2 = \arg \max_{k=1,\dots,c} \hat{p}_k(R_2) \text{ é a classe dominante no retângulo } R_2 \quad (\text{Eq. 3.28})$$

Para se encontrar o ponto  $t$  de divisão de uma região  $R_m$  precisa-se considerar apenas  $n_m-1$  divisões do atributo de previsão  $X_j$  a ser examinado.

Para os novos nós procede-se de forma análoga, até que seja satisfeito um critério de paragem, por exemplo quando todos os dados pertencerem a uma determinada classe. Para uma árvore  $T$ , denote-se por  $\#T$  o seu numero de folhas e, para  $\alpha \geq 0$ ,

$$C_\alpha(T) = \sum_{j=1}^{\#T} ((1-p_{c_j}(R_j)) + \alpha \cdot \#T) \quad (\text{Eq. 3.29})$$

Assim o algoritmo CART escolhe a árvore  $T$  que minimiza  $C_\alpha(T)$  recorrendo a validação cruzada. Existindo uma regularização na vez que se penaliza árvores com muitas folhas.

### ***Tratamento dos dados de treino***

Como já referindo anteriormente o algoritmo RPART foi utilizado como classificador de valores discretos. Uma vez que as saídas (valores a prever) eram todos diferentes (quase que considerando como valores contínuos) foi necessário categorizar os valores em regiões bem definidas para os valores em questão. Para isso utilizou-se a seguinte formula:

$$\text{Categoria} = \text{ROUND}(\text{Valor} * 20) / 20 \quad (\text{Eq. 3.30})$$

Desta forma todos os valores de saída iriam-se encontrar na categoria correspondente ao arredondamento feito às 5 centésimas. Por exemplo 0.9274 seria categorizado como 0.95, 1.411

seria categorizado como 1.4. Sendo que para o cálculo do erro são utilizadas as categorias originárias da aplicação da forma ao valor e não ao valor em si.

## 4 ESTUDO EMPÍRICO

Nesta secção é apresentado os resultados obtidos das experiências executadas e que permitem a conclusão do estudo. Foram apresentados os gráficos e resultados que se julgam ser os necessários para poder chegar a uma conclusão fidedigna. No entanto é possível verificar a totalidade do estudo nos Anexos.

É nesta secção que também é descrito e justificado o caminho seguido no estudo, assim como definido as hipóteses e os objetivos do mesmo.

### 4.1 Apresentação do Estudo

Nesta secção é feita a apresentação do estudo de forma clara. Com esta apresentação pretende-se dar a conhecer de forma inequívoca o que está em causa e justificar algumas decisões inerentes á execução do estudo.

#### 4.1.1 Introdução

O objetivo do estudo proposto nesta secção é criar, analisar e avaliar dois métodos de modelação, através de redes neuronais e árvores de decisão, que possa permitir a previsão do impacto das estratégias, utilizadas por uma organização, nos resultados financeiros, nomeadamente no volume de negócios. As metodologias escolhidas para modelação, como referido anteriormente, são baseadas numa área da ciência da computação, designada por inteligência artificial, mais especificamente a primeira através de redes neuronais artificiais (RNA) e a segunda através de árvores de decisão (AD). As RNA têm dado resultados conhecidos e motivadores na área da modelação de ambientes não lineares propensos a ruído nos dados. As ADs têm mostrado mais valências nos sistemas de decisão ou sistemas periciais.

O estudo foca-se em analisar a possibilidade da modelação e não na construção efetiva dos modelos para esse efeito. A criação dos modelos está inerente à necessidade de medir o desempenho para prova da hipótese. Isto é, o foco do estudo é a análise do desempenho dos modelos construído como prova da possibilidade do uso dos métodos desenvolvidos para previsão do impacto da utilização de estratégias nos resultados financeiros.

Este método inovador consiste em utilizar as RNAs e as ADs para modelar o comportamento dos resultados financeiros (volume de negócios) de acordo com as estratégias aplicadas pela organização.



#### 4.1.2 Objetivos Principais

O objetivo principal inerente ao estudo é a criação e análise de desempenho de dois métodos de modelação que permitam prever o impacto das estratégias, utilizadas em PME's portuguesas, nos resultados financeiros, nomeadamente no volume de negócios.

A análise de desempenho do modelo deve permitir chegar a uma conclusão sobre a possibilidade de utilização destes modelos para prever os resultados financeiros mediante o conhecimento prévio das estratégias utilizadas. Inerente a esta conclusão está a possibilidade de as estratégias utilizadas terem um impacto direto nos resultados financeiros.

O Modelo do Ambiente Estratégico será conseguido através de duas técnicas computacionais, ambas inerentes a uma área da informática em amplo crescimento e investigação, quer no mundo académico quer no mundo empresarial, denominada de Inteligência Artificial (IA, ou em inglês *Artificial Intelligence*, AI). As técnicas a serem utilizadas são designadas por Redes Neurais Artificiais (RNAs) e Árvores de Decisão (ADs).

As análises de desempenho aos modelos criados são independentes das técnicas utilizadas. Isto é, apesar da tentativa de formatar a apresentação dos resultados da mesma forma para ambas as técnicas, a modelação dos ambientes estratégicos é produzida com os mesmos dados, mas sem cruzamento de informação entre as técnicas utilizadas. Desta forma é possível comparar o desempenho das técnicas entre si, de uma forma clara e transparente.

#### 4.1.3 Hipóteses de Observação

Este estudo está inerente a duas hipóteses. Ambas as hipóteses serão alvo de um estudo sobre a possibilidade de a precisão dos modelos preditivos poderem ser utilizados com o objetivo pelo qual foram criados. As hipóteses estão associadas à possibilidade de utilizar os modelos criados para prever as ações sobre determinado ambiente estratégico, ficando assim definidas:

- 1) Hipótese A: esta hipótese debruça-se sobre a possibilidade de construir um modelo, utilizando RNAs que permitam a construção de um modelo de previsão de resultados através de estratégias: Este modelo deve ter como entrada as estratégias a utilizar no respetivo ano. Como saídas deve produzir os resultados esperados pela utilização das estratégias definidas na entrada

- 2) Hipótese B: esta hipótese debruça-se sobre a possibilidade de construir um modelo, utilizando ADs que permitam a construção de um modelo de previsão de resultados através de estratégias: Este modelo deve ter como entrada as estratégias a utilizar no respetivo ano. Como saídas deve ter os resultados esperados pela utilização das estratégias definidas na entrada. As saídas (resultados) das ADs são categorizadas por intervalo de aumento/diminuição esperada dos resultados financeiros.

As hipóteses serão estudadas e analisadas em separado. Cada hipótese tem a sua análise aos modelos inerentes, através dos resultados e matriz de desempenho obtidas pela modelação dos conjuntos de avaliação (conjuntos de teste). A determinação do nível de sucesso para cada uma das técnicas é feito individualmente, sendo providenciado uma análise comparativa entre as duas metodologias.

### 4.2 Dados

Nesta secção são descritos os dados inerentes ao estudo, desde o questionário aos resultados financeiros. Pretende-se dar a conhecer a forma como foram obtidos, tratados e processados os dados utilizados para criação e teste dos modelos estratégicos. É também descrita a nomenclatura utilizada para cada um dos modelos assim como a sua forma de criação e quais os dados inerentes a cada um dos modelos.

#### 4.2.1 Questionário

##### *Formulação*

A formulação do questionário foi cuidadosamente pensada para poder ser compreensível pelos inquiridos. Existiram duas preocupações principais, a primeira é que fosse de fácil e rápida resposta e a segunda é que não existisse uma especificidade em cada estratégia apresentada, devido a três razões:

- 1) Problemas de confidencialidade apresentados pelos inquiridos, com estratégias gerais poderia existir maior adesão por parte dos inquiridos a responder
- 2) Especificidade das estratégias poderia levar a um número elevado de perguntas, e por conseguinte, a um número elevado nas entradas da rede neuronal, e por isso, a um treino mais difícil e com menor desempenho.

- 3) Com estratégias específicas poder estar-se a limitar demasiado o número de empresas que poderiam ser inquiridas. Mantendo um nível geral das estratégias poder-se-ia abranger um número elevado de empresas e com isso ter a quantidade de informação adequada para o estudo.

Em relação ainda à primeira preocupação é necessário referir que foi dada em cada pergunta uma pequena descrição e ou exemplo da estratégia descrita, de forma a tornar compreensível qual era o objetivo da aplicação da mesma. Desta forma, tentou-se criar um questionário que permitiria um número elevado de adesões por parte dos inquiridos, baseado na rapidez e facilidade da resposta.

O questionário tem como alvos principais os anos de 2013, 2014 e 2015 pelos motivos apresentados na secção 1.1. Os resultados financeiros a ter em consideração são os de 2012, 2013, 2014 e 2015. Não existindo necessidade de incluir no questionário o ano de 2012, uma vez os resultados financeiros de 2012 servem apenas para calcular o rácio entre 2012 e 2013.

Cada pergunta do questionário foca-se no nível de aplicação dessa estratégia por parte da organização. Desta forma não só se pretende saber a importância da estratégia para a organização, como também, de uma forma geral, como a organização perspetiva o impacto da aplicação dessa estratégia nos seus resultados.

### *As estratégias*

As estratégias que foram escolhidas para fazer parte do questionário são estratégias que podem estar presentes em qualquer ramo de atividade, com isto pretendeu-se abranger um número elevado de empresas que pudessem fazer parte do universo de inquiridos.

Relembra-se que as estratégias existentes no questionário aos gestores foram as seguintes:

- 1) Preço de Produto
- 2) Qualidade do Produto
- 3) Redução de Custos
- 4) Investimento
- 5) Financiamento
- 6) Diversificação/Especialização de Produto
- 7) Aumento/Redução de Mercados
- 8) Sinergias Comerciais

- 9) Divulgação de Produtos
- 10) Reorganização Estrutural
- 11) Renegociação com Fornecedores

O questionário tem como objeto as estratégias utilizadas nas organizações quer o nível de aplicação das estratégias, isto é, a importância que a organização dá a determinada estratégia, assim como o nível de sucesso na aplicação da estratégia, ou seja, como a organização perspetiva o impacto da aplicação dessa estratégia nos resultados. As respostas do nível de sucesso da aplicação das estratégias foram descartadas uma vez que não existiam diferenças significativas para o nível de aplicação das estratégias, isto é, os gestores consideraram que as estratégias tinham tido um sucesso idêntico aquele para o qual foram concebidas.

### ***Dados***

O estudo empírico assenta a sua viabilidade num questionário, apresentado no Anexo A.1, feito a 37.904 empresas, do qual responderam 448 empresas. Empresas estas que se inserem na classificação de micro ou pequenas empresas, segundo o IAPMEI, isto é, empresas que tenha de 5 a 50 trabalhadores e um volume de negócios inferior a 10.000.000€. Cada empresa respondeu aos 3 anos pelo que totaliza o equivalente a 1344 questionários respondidos.

#### **4.2.2 Dados Financeiros**

Após a conclusão do questionário os dados sobre as estratégias utilizadas foram associados aos dados dos resultados financeiros dos anos 2012, 2013, 2014 e 2015, retirados da base de dados do SABI. Existiu uma análise dos dados e delineou-se um caminho objetivo a seguir. Esse caminho foi determinado pela quantidade e qualidade das respostas do questionário.

Foram retirados os dados da base de dados SABI (<http://sabi.bdvinfo.com>) informação financeira referente ao ano de 2012, 2013, 2014 e 2015 para as organizações objeto da análise. As informações retiradas para o estudo foram:

- 1) Volume de Negócios
- 2) Resultados Operacionais
- 3) Resultados Líquidos
- 4) Rendibilidade Económica
- 5) Rendibilidade Financeira
- 6) EBIT
- 7) EBITDA
- 8) Rácio de Solvabilidade

Os dados foram analisados e os considerados relevantes para o estudo foram o Volume de Negócios e os Resultados Operacionais. A análise dos dados foi feita numa vertente de verificação de estabilidade financeira das organizações. Esta análise teve como objetivo uma ponderação de quais as organizações a serem utilizadas no estudo e criação dos modelos.

As organizações que não se enquadram num conceito de estabilidade financeira podem não oferecer garantias sobre a correta aplicação das estratégias ou que as estratégias aplicadas tenham um efeito significativo nos resultados financeiros.

No âmbito do estudo o interesse está na alteração dos resultados financeiros de um ano para outro. Desta forma foram calculadas as variações (designadas por delta;  $\delta$ ). Este valor representa a variação de um determinado resultado de um ano para o resultado do ano seguinte. É este valor que é utilizado para a modelação e avaliação do modelo durante o decorrer do estudo.

#### 4.2.3 Modelos dos Ambientes Estratégicos

No âmbito do estudo das hipótese apresentadas foram modelados os ambientes relativos a 3 anos consecutivos (2013, 2014 e 2015), onde se utilizou o conjunto de dados considerados e resultantes da secção 4.2. Para teste do modelo foram utilizadas 6 combinações:

- 1) Modelo estratégico ano 2013 criado a partir de parte dos dados obtidos para 2013 (conjunto treino) e avaliado com os restantes dados de 2013 (conjunto teste). O conjunto de avaliação é obtido previamente de forma aleatória e onde o número de amostras têm uma razão de cerca de 70% e 30%, respetivamente. Doravante designado por **Modelo Estratégico 2013** (ME13).
- 2) Modelo estratégico ano 2014 criado a partir de parte dos dados obtidos para 2014 (conjunto treino) e avaliado com os restantes dados de 2014 (conjunto teste). O conjunto de avaliação é obtido previamente de forma aleatória e onde o número de amostras têm uma razão de cerca de 70% e 30%, respetivamente. Doravante designado por **Modelo Estratégico 2014** (ME14).
- 3) Modelo estratégico ano 2015 criado a partir de parte dos dados obtidos para 2015 (conjunto treino) e avaliado com os restantes dados de 2015 (conjunto teste). O conjunto de avaliação é obtido previamente de forma aleatória e onde o número de amostras têm uma razão de cerca de 70% e 30%, respetivamente. Doravante designado por **Modelo Estratégico 2015** (ME15).

- 4) Modelo estratégico ano 2013 criado a partir da totalidade dos dados obtidos para 2013 (conjunto treino) e avaliado com a totalidade dos dados de 2014. Doravante designado por **Modelo Estratégico 2013 – Conjunto de Teste 2014** (ME13T14).
- 5) Modelo estratégico ano 2014 criado a partir da totalidade dos dados obtidos para 2014 (conjunto treino) e avaliado com a totalidade dos dados de 2015. Doravante designado por **Modelo Estratégico 2014 – Conjunto de Teste 2015** (ME14T15).
- 6) Modelo estratégico Global criado a partir da totalidade dos dados obtidos (2013, 2014 e 2015). Onde o conjunto treino e o conjunto de avaliação é obtido de forma aleatória e onde o número de amostras têm uma razão de 70% e 30%, respetivamente. Doravante designado por **Modelo Estratégico Global** (MEGlobal).

Para cada modelo definido foram ainda definidos 8 algoritmos de RNAs para a plataforma R (CRAN), 1 algoritmo para a plataforma NetConsole (Sony), exceto MEGlobal, e 1 algoritmo para árvores de decisão, totalizando a construção de 59 Modelos:

	Redes Neurais Artificiais									Árvores de Decisão
	Plataforma R (CRAN)								NetConsole	Plataform R (CRAN)
	RProp-	Rprop+	SAG	Rprop Avg	AVG6	Rprop-/Q	Rprop+/Q	SAG/Q	Personalizado	Rpart (Class)
ME13	X	X	X	X	X	X	X	X	X	X
ME14	X	X	X	X	X	X	X	X	X	X
ME15	X	X	X	X	X	X	X	X	X	X
ME13T14	X	X	X	X	X	X	X	X	X	X
ME14T15	X	X	X	X	X	X	X	X	X	X
MEGlobal	X	X	X	X	X	X	X	X		X

*Tabela 4-1: Combinações de modelos, algoritmos plataformas e metodologias.*

Para identificação dos modelos utilizou-se uma nomenclatura que permite serem identificados de uma forma simples, rápida e eficiente. A nomenclatura é criada segundo as seguintes regras:

- 1) Os conjuntos utilizados para o treino e para o teste (se diferente do conjunto treino).  
ME13; ME14; ME15; ME13T14; ME14T15; MEGlobal
- 2) A metodologia/plataforma
  - i. R : RNA de R CRAN
  - ii. NC : RNA NetConsole (Sony)
  - iii. ADR : Árvore de Decisão R CRAN
- 3) O algoritmo (se a plataforma for R CRAN e a metodologia for RNA).  
RProp-; RProp+; SAG; RProp Avg; AVG6; RProp-/Q; RProp+/Q; SAG/Q

O ‘/Q’ existente após o algoritmo significa que os dados de entrada sofreram uma alteração através de uma normalização, descrito com mais detalhe na secção ‘Normalização das Respostas ao Questionário’, no capítulo 4.2.4. Sem o pós-fixado significa que as entradas da RNA sofreram uma alteração por um fator divisor descrito na Tabela 4-7.

Por exemplo ME13T14ADR significa que modelo foi obtido pelo treino dos dados do ano 2013 e avaliado com os dados do ano 2014, utilizando a metodologia de Árvores de Decisão na plataforma R. No caso da nomenclatura for MEGlobalR (RProp+/Q). sabe-se que o Modelo Estratégico modelado utilizou a totalidade dos dados considerados válido nos 3 anos (2013, 2014 e 2015), onde o conjunto treino e conjunto teste foram obtidos de forma aleatória, na razão de 70% das amostras para o conjunto treino e 30% das amostras para o conjunto teste. Utilizou-se o algoritmo RProp+ da plataforma R (CRAN) e as entradas foram normalizadas em relação ao global das respostas do gestor.

#### 4.2.4 Tratamento dos dados

Os dados e informações, quer os obtidos através do questionário aos gestores, quer dos dados financeiros provenientes da plataforma SABI, foram alvo de processamento de forma a filtrar as companhias consideradas válidas e ou de melhorar o desempenho das metodologias ou técnicas que serviram para modelar os ambientes estratégicos inerentes e necessários ao estudo.

##### *Dados do Questionário*

Os dados resultantes do questionário foram representados na forma de inteiros, negativos ou positivos, consoante a estratégia e que pode ser consultada na seguinte tabela:

Questões	Estratégia	Interval	Observações
Q1	Aumento/Redução de Preço	[-9,9] e Z	Redução: Negativo Aumento: Positivo
Q2	Aumento/Redução de Qualidade	[-9,9] e Z	Redução: Negativo Aumento: Positivo
Q3	Redução de Custo de Pessoal	[0,9] e	
Q4	Investimento	[0,9] e	
Q5	Diminuição Financiamento	[0,9] e	
Q6	Diversificação/Especialização de Produto	[-9,9] e Z	Especialização: Negativo
Q7	Redução/Aumento de Clientes ou Mercados	[-9,9] e Z	Aumento: Negativo Redução: Positivo
Q8	Sinergias Comerciais	[0,9] e	
Q9	Divulgação de Produtos	[0,9] e	
Q10	Reorganização Empresarial	[0,9] e	

## ESTUDO EMPÍRICO

Questões	Estratégia	Interval	Observações
Q11	Renegociação com Fornecedores	[0,9] €	

Tabela 4-2: Representação numérica das estratégias no questionário

Desta forma o seguinte exemplo representa as respostas ao questionário por parte de várias organizações:

	Emp 1	Emp 2	Emp 3	Emp 4	Emp 5	Emp 6	Emp 7	Emp 8	Emp 9
q1a2013	2	0	0	5	0	0	0	8	0
q1a2014	2	0	0	5	0	0	5	8	0
q1a2015	2	0	0	5	0	0	5	8	0
q2a2013	4	0	-4	4	-4	0	0	1	0
q2a2014	5	0	-5	0	-4	0	-5	1	0
q2a2015	5	0	-5	0	-4	0	-5	1	0
q3a2013	7	0	4	8	4	0	0	6	4
q3a2014	7	0	5	8	4	0	0	7	4
q3a2015	7	0	5	8	4	0	0	7	4
q4a2013	0	0	4	0	2	0	0	0	2
q4a2014	0	2	5	0	3	0	5	0	2
q4a2015	0	2	5	0	3	0	5	0	2
q5a2013	0	0	3	5	2	0	0	4	0
q5a2014	0	0	6	3	2	0	0	6	0
q5a2015	0	0	6	3	2	0	0	6	0
q6a2013	0	0	0	9	0	0	0	2	0
q6a2014	0	0	0	9	0	0	5	1	0
q6a2015	0	0	0	9	0	0	5	1	0
q7a2013	-7	0	-4	-4	0	0	9	-8	0
q7a2014	-7	0	-5	-5	0	0	9	-8	0
q7a2015	-7	0	-5	-5	0	0	9	-8	0
q8a2013	-4	0	3	-5	-3	0	0	-5	0
q8a2014	-5	0	4	-5	-3	0	0	-7	0
q8a2015	-5	0	4	-5	-3	0	0	-7	0
q9a2013	5	0	0	4	0	0	5	3	0
q9a2014	5	0	0	3	0	0	5	4	0
q9a2015	5	0	0	3	0	0	5	4	0
q10a2013	2	0	5	5	6	0	5	0	1
q10a2014	2	0	4	5	6	0	7	8	1
q10a2015	2	0	4	5	6	0	7	8	1
q11a2013	1	0	3	0	4	0	0	3	0
q11a2014	1	1	4	0	4	0	5	3	0
q11a2015	1	1	4	0	4	0	5	3	0

Tabela 4-3: Exemplo da representação dos dados das empresas

Note-se que para cada questão existe uma representação específica para cada um dos anos relativos ao estudo, os anos 2013, 2014 e 2015.



A distribuição da soma absoluta das respostas, para os diferentes anos, pode ser visualizada nas figuras Figura 4.1, Figura 4.2 e Figura 4.3. A visualização desta distribuição ajuda a perceber, de uma forma geral, o comportamento dos gestores em relação à importância das estratégias nas organizações. Os valores destas distribuições estão disponíveis na Tabela A-1 (ver anexos).




Figura 4.1: Distribuição da soma absoluta das respostas de 2013




Figura 4.2: Distribuição da soma absoluta das respostas de 2014




Figura 4.3: Distribuição da soma absoluta das respostas de 2015

Note-se que existiram um número considerável de organizações que não respondeu ou que não aplicou qualquer estratégia nos anos observados (soma absoluta igual a 0).

Para os dados dos questionários calculou-se a soma absoluta para cada um dos anos e considerou-se como comportamento normal dos gestores o intervalo  $[\mu - 1.30 \cdot \sigma, \mu + 1.30 \cdot \sigma]$ . Os valores podem ser verificados na tabela seguinte:

	Média	Variância	Desvio Padrão	Min	Max
2013	28.080	334.450	18.288	4.30	51.85
2014	31.605	349.586	18.697	7.29	55.91
2015	35.634	411.642	20.289	9.25	62.01
Total	31.773	374.213	19.345	n/a	n/a

Tabela 4-4: Dados do comportamento estratégico dos gestores

Todos os dados do questionário que não correspondiam ao comportamento considerado normal foram eliminados. Neste sentido a soma absoluta das respostas dadas para um determinado ano por um gestor apenas são aceites para fazer parte do modelo se estiver entre o mínimo e o máximo descritos na Tabela 4-4.

Por exemplo, para o ano 2013, todos os dados dos inquéritos com comportamento cuja soma absoluta era inferior a 4.30 e superior a 51.85, foram eliminados. Isto deve-se ao facto de se pretender reduzir o ruído existente no treino dos modelos. Por exemplo, respostas com 7 a todas as questões, comparativamente com as outras respostas significa que muito provavelmente o gestor não estava a ser sincero ou que não tinha compreendido o propósito do questionário.

Após a eliminação dos dados pela análise do comportamento estratégico que os gestores demonstraram na realização do questionário ficou-se com a seguinte quantidade de amostras consideradas, nesta fase, como válidas:

Ano	#Amostras	Eliminadas
2013	350	98
2014	353	95
2015	351	97

*Tabela 4-5: Número de amostras com comportamento válido*

Pode verificar-se que as organizações têm um comportamento estratégico semelhante a uma distribuição normal. Para os efeitos deste estudo e uma vez que não existem estudos relativos a este comportamento irá considerar-se este pressuposto. Os comportamentos que não se enquadram com a maioria das organizações podem criar ruído indesejado nas análises inerentes ao estudo. Este deve ser minimizado através da eliminação, das análises, dos dados referentes às organizações que não se enquadram com a distribuição do comportamento estratégico da maioria das organizações.

### ***Dados Financeiros***

Foram retirados os dados da base de dados SABI (<http://sabi.bdvinfo.com>) informação financeira referente ao ano de 2012, 2013, 2014 e 2015 para as organizações objeto da análise. As informações consideradas para análise foram:

- 1) Volume de Negócios
- 2) Resultados Operacionais
- 3) Resultados Líquidos

Uma análise de cada um destes pontos para as organizações referenciadas no estudo permitiu perceber alguns problemas que poderiam surgir na modelação estratégica vs resultados.

A diversidade existente nos dados induziu alguns critérios de avaliação referentes à tentativa de modelação. Permitiu que se inferisse que alguns destes resultados nada deveriam ter a ver com as estratégias utilizadas e que a introdução destas organizações em fases posteriores ao estudo poderiam ter impacto significativo e negativo na tentativa de modelação estratégica.

Por exemplo, uma organização que aumentasse o seu volume de negócios 500% em 2014 relativamente a 2013, normalmente não se poderia associar estas alterações a uma estratégia, mas

a um fator extraordinário. Outro exemplo seria uma empresa cujos resultados operacionais fossem negativos, podendo estar presentes problemas na estrutura da organização e tendo impacto negativo, só por si, na aplicação das estratégias. Assim, da mesma forma que se eliminou as empresas que não se enquadravam no perfil desejado ou dúbio em relação à aplicação de estratégias, optou-se por eliminar os dados das organizações que não se enquadravam num perfil de estabilidade financeira.

Foram definidos alguns conceitos operacionais como regras para aceitação/eliminação dos dados referentes às organizações para o estudo:

- 1) Volume de Negócios:
  - a. o  $\delta$  não deve ser inferior a -50% ou superior a 100%.
- 2) Resultados Operacionais:
  - a. Os resultados operacionais devem ser positivos.
  - b. O  $\delta$  não deve ser inferior a -40% ou superior a 100%.

sendo que por “delta” ( $\delta$ ) deve-se entender,

$$\delta = \frac{\text{resultado}_{\text{ano}} - \text{resultado}_{\text{ano}-1}}{\text{resultado}_{\text{ano}-1}} \times 100 (\%) \quad (\text{Eq. 4.1})$$

Com este método exclui-se os dados das organizações que podem ter sido alvo de situações não estratégicas e que porventura possam ter tido impacto nos resultados.

	Válidas	Eliminadas
2013	128	222
2014	178	175
2015	166	185
Total	472	582

*Tabela 4-6: Número de amostras elegíveis para modelação*

A Tabela 4-6 contabiliza todas as amostras elegíveis para o treino e avaliação dos respetivos modelos. Por exemplo para o Modelo Estratégico Global têm-se 472 amostras, para treino e avaliação. Já para o Modelo Estratégico 2013 – Conjunto Teste 2014 têm-se 128 amostras para treino do modelo e 178 amostras para avaliação do mesmo.

### ***Categorização dos Resultados Financeiros***

Dependendo da metodologia e plataforma é necessário preparar os dados para aumentar a eficácia da modelação. Isto é, enquanto certas metodologias permitem que os dados sejam utilizados em bruto, sem processamento adicional, outras exigem um processamento de forma a que permita à metodologia a utilizar uma otimização nos resultados desejados.

O caso das árvores de decisão é que os resultados de saída sejam discretos, ou de alguma forma categorizados, uma vez que se pretende árvores de decisão categóricas. Desta forma o erro é calculado em relação à categoria esperada e à categoria calculada.

Para o caso da modelação dos resultados criou-se categorias baseadas no valor dos resultados (delta) arredondado às 5 décimas.

$$Categoria(Valor) = \frac{ROUND(Valor*20)}{20} \quad (Eq. 4.2)$$

Isto significa que os valores do delta dos resultados financeiros são transformados de acordo com a Tabela A-2 (ver anexos).

### ***Normalização das Respostas ao Questionário***

Da mesma forma que a categorização das saídas pode trazer uma otimização no treino do modelo, a normalização das entradas pode trazer um aumento de desempenho do modelo preditivo, dependendo da metodologia a utilizar. Por exemplo no caso das redes neurais a normalização das entradas para valores entre -1 e 1 pode trazer melhorias significativas no treino da rede.

Modelo	Algoritmo	Factor de Normalização
ME13	Rprop-	14
ME13	Rprop+	14
ME13	SAG	14
ME13	Rprop Avg	9
ME13	AVG6	18
ME14	Rprop-	14
ME14	Rprop+	14
ME14	SAG	14
ME14	Rprop Avg	9
ME14	AVG6	18
ME15	Rprop-	14
ME15	Rprop+	14
ME15	SAG	14
ME15	Rprop Avg	9
ME15	AVG6	18
ME13T14	Rprop-	14
ME13T14	Rprop+	14

## ESTUDO EMPÍRICO

Modelo	Algoritmo	Factor de Normalização
ME13T14	SAG	14
ME13T14	Rprop Avg	9
ME13T14	AVG6	18
ME14T15	Rprop-	14
ME14T15	Rprop+	14
ME14T15	SAG	14
ME14T15	Rprop Avg	9
ME14T15	AVG6	18
MEGlobal	Rprop-	14
MEGlobal	Rprop+	14
MEGlobal	SAG	14
MEGlobal	Rprop Avg	14
MEGlobal	AVG6	9

*Tabela 4-7: Fator de divisão do valor das entradas das RNAs(R)*

Desta forma para o ME14 (RProp-) a Tabela 4-8:

Q1 a2014	Q2a 2014	Q3a 2014	Q4a 2014	Q5a 2014	Q6 a2014	Q7 a2014	Q8 a2014	Q9 a2014	q10 a2014	q11 a2014	Soma Absoluta
-1	-1	4	7	2	-5	-6	0	6	0	4	36
0	5	3	7	0	-3	-5	0	6	4	6	39
5	9	0	6	6	0	0	4	5	4	7	46
-6	0	8	0	0	0	-8	0	5	0	0	27
-6	0	0	5	0	5	0	0	6	0	7	29

*Tabela 4-8: Exemplo valores do questionário*

Seria transformada em:

Q1 a2014	Q2a 2014	Q3a 2014	Q4a 2014	Q5a 2014	Q6 a2014	Q7 a2014	Q8 a2014	Q9 a2014	Q10 a2014	q11 a2014
-0.0714	-0.0714	0.2857	0.5000	0.1429	-0.3571	-0.4286	0.0000	0.4286	0.0000	0.2857
0.0000	0.3571	0.2143	0.5000	0.0000	-0.2143	-0.3571	0.0000	0.4286	0.2857	0.4286
0.3571	0.6429	0.0000	0.4286	0.4286	0.0000	0.0000	0.2857	0.3571	0.2857	0.5000
-0.4286	0.0000	0.5714	0.0000	0.0000	0.0000	-0.5714	0.0000	0.3571	0.0000	0.0000
-0.4286	0.0000	0.0000	0.3571	0.0000	0.3571	0.0000	0.0000	0.4286	0.0000	0.5000

*Tabela 4-9: Exemplo de valores após divisão por fator (ME14 RProp-)*

Outra normalização que se vai executar em alguns modelos é relativo ao questionário. Uma vez que não existem dados que possam fazer compreender o significado de cada valor para cada um dos gestores e uma vez que não é possível, de forma objetiva, avaliar qual o significado dos níveis de aplicação para cada um dos gestores que respondeu ao inquérito, a forma utilizada para ultrapassar este obstáculo foi o de normalizar os resultados do inquérito. O pressuposto subjacente

a esta normalização é o facto de que as respostas representam as prioridades que cada organização tem na aplicação das suas estratégias.

Desta forma uma organização que respondeu que tem um nível de aplicação 5 a quatro estratégias e 0 a todas as outras tem uma prioridade de aplicação de 0,25 a cada uma das estratégias, da mesma forma que uma organização que respondeu um nível aplicação 3 a duas estratégias e um nível de aplicação 6 a outras duas estratégias na realidade tem uma prioridade de aplicação de 0,166 a duas estratégias e de 0,333 a outras duas estratégias.

A normalização permite relacionar os dados respondidos individualmente a cada um dos questionários. Assim consegue-se, de forma mais precisa, compreender os valores obtidos em cada um dos questionários e utiliza-los para relacionar o nível de aplicação das estratégias com os resultados.

Por este motivo, alguns dos modelos criados através das redes neuronais (R CRAN) foram alvo de criação a partir dos dados de entrada normalizados.

Para conseguir uma normalização dos dados divide-se cada uma das estratégias pela soma absoluta do ano em questão. Assim, por exemplo, tem-se:

Normalizando a Tabela 4-8 de valores do questionário para as respetivas empresas ter-se-ia:

Q1 a2014	Q2a 2014	Q3a 2014	Q4a 2014	Q5a 2014	Q6 a2014	Q7 a2014	Q8 a2014	Q9 a2014	q10 a2014	q11 a2014	Soma Absoluta
-0,028	-0,028	0,111	0,194	0,056	-0,139	-0,167	0	0,167	0	0,111	1
0	0,128	0,077	0,179	0	-0,077	-0,128	0	0,154	0,103	0,154	1
0,109	0,196	0	0,13	0,13	0	0	0,087	0,109	0,087	0,152	1
-0,222	0	0,296	0	0	0	-0,296	0	0,185	0	0	1
-0,207	0	0	0,172	0	0,172	0	0	0,207	0	0,241	1

*Tabela 4-10: Exemplo valores do questionário normalizados*

Estes valores normalizados serão os valores a serem utilizados para as entradas da rede neuronal, para os casos dos modelos referenciados com o pós-fixado '/Q'. Por exemplo ME13R (RProp+/Q).

### 4.3 Interpretação dos Resultados

Para uma correta interpretação dos resultados é necessário descrever um conjunto de diretivas utilizadas na interpretação dos gráficos e tabelas que, por conseguinte, levem a uma correta compreensão dos resultados. Nesta secção são descritas as metodologias utilizadas para

interpretação, e por conseguinte análise, dos resultados obtidos pela utilização das metodologias descritas. De uma forma clara é possível avaliar os resultados gráficos assim como estabelecer relações entre os gráficos e tabelas apresentadas.

#### 4.3.1 Gráficos: Comparativo de Valores por Amostra

Os gráficos demonstrativos dos valores consoantes as amostras permitem visualizar de uma forma rápida e fácil o comportamento da modelação para o conjunto teste (avaliação). A linha azul representa os valores reais e a linha laranja representa os valores previstos pela modelação. Note-se que os valores reais (linha azul) são valores crescentes derivado a uma ordenação prévia dos resultados pelo valor real. Desta forma consegue-se visualizar mais facilmente o comportamento dos valores esperados (reais) em comparação com o comportamento dos valores da previsão.




Figura 4.4: Exemplo - Valores e médias por amostra  $c/erro < 30\%$ .




Figura 4.5: Exemplo - Valores e médias por Amostra  $c/erro < 20$

No gráfico estão representadas mais duas funções. A linha amarela que representa o valor médio de dos os valores reais até à amostra  $n$ , e a linha cinzenta que representa o valor médio dos valores previstos até à amostra  $n$ . Deve-se ter especial atenção que no cálculo do valor médio apenas são contabilizadas as amostras que pertencem ao grupo de verificação:  $erro < 30\%$  ou  $erro < 20\%$ .



Neste sentido a linha azul, e, por conseguinte, a linha amarela, representam sempre uma função crescente, no limite uma função uniforme, caso todas as amostras tivessem um valor igual. A linha laranja é espectável que tenha oscilações, devido à natureza da modelação. Para se considerar um bom modelo o comportamento da função inerente aos valores previstos (linha laranja) deverá acompanhar, ainda que de forma oscilatória, a linha azul. Analogamente a função referente à média dos valores previstos (linha cinzenta) deverá ter um comportamento aproximado à função referente à média dos valores reais (linha amarela).

Exemplos:




Figura 4.6: Exemplo gráfico considerado como boa modelação



Figura 4.7: Exemplo gráfico considerado como má modelação

Figura 4.6 a função dos valores previstos acompanha, ainda que de forma oscilatória, a função dos valores reais. É visível um acompanhamento e ajustamento da função da média dos valores previstos à função das médias dos valores reais. Estes fatores são sinal que os valores previstos não são calculados de forma aleatória e têm uma ligação aos valores reais. No entanto na Figura 4.7 existe alguma dificuldade em verificar um acompanhamento ou adaptação da função da média dos valores previstos à função da média dos valores reais.


É preciso referir que nas primeiras amostras os valores médios previstos e valores médios reais podem diferenciar significativamente, uma vez que devido á natureza oscilatória do modelo só após a inclusão de algumas amostras é que pode começar a existir alguma tendência da função da média dos valores previstos se adaptar à função média dos valores reais.

Desta forma definiu-se a seguinte tabela para avaliação da modelação em função do comportamento inerente aos valores previstos versus valores reais:

Classificação	Observação
Mau	Não se vislumbra graficamente qualquer acompanhamento
Ligeiro	Os valores previstos acompanham ligeiramente o comportamento dos valores reais
Médio	Os valores previstos acompanham o comportamento dos valores reais ainda que com uma margem de erro
Bom	Os valores previstos acompanham de forma facilmente identificável o comportamento dos valores reais

*Tabela 4-11: Classificação do comportamento gráfico dos valores previstos*

Já para o gráfico de ‘Comparativo de Valores por Amostra’ para amostras com erro superior a 30%, como a Figura 4.8. Não se pode tirar qualquer ilação apesar de um acompanhamento por parte da função de valores previstos à função de valores reais constituir um bom presságio na qualidade da modelação.



*Figura 4.8: Exemplo - Valores por amostra c/erro>30%*

Note-se que as amostras representadas graficamente são aquelas que são consideradas como com erros excessivos. O comportamento desta função determina como se comportam os erros resultantes do modelo.

### 4.3.2 Gráficos: Modelação do Conjunto de Testes (Previsão vs Real)




Figura 4.9: Exemplo - Modelação do conj. de Teste. (Prev. vs Real)

A Figura 4.9 representa os valores com coordenadas  $(y, y')$  onde  $y$  é o valor real e  $y'$  o valor previsto pelo modelo. Neste sentido quando as coordenadas são  $(y, y)$  (linha azul) considera-se uma previsão ótima do valor real. Quanto mais distante este ponto estiver da linha diagonal azul maior será o erro da previsão. As duas linhas auxiliares identificam a área onde se encontram os pontos com erro inferior a 30%. Neste gráfico também é possível conhecer a amplitude dos valores do modelo, ou seja, o mínimo e o máximo do eixo  $y'$ .

O gráfico “Modelação do Conjunto de Testes” está diretamente relacionado com os gráficos comparativos de valores por amostra.

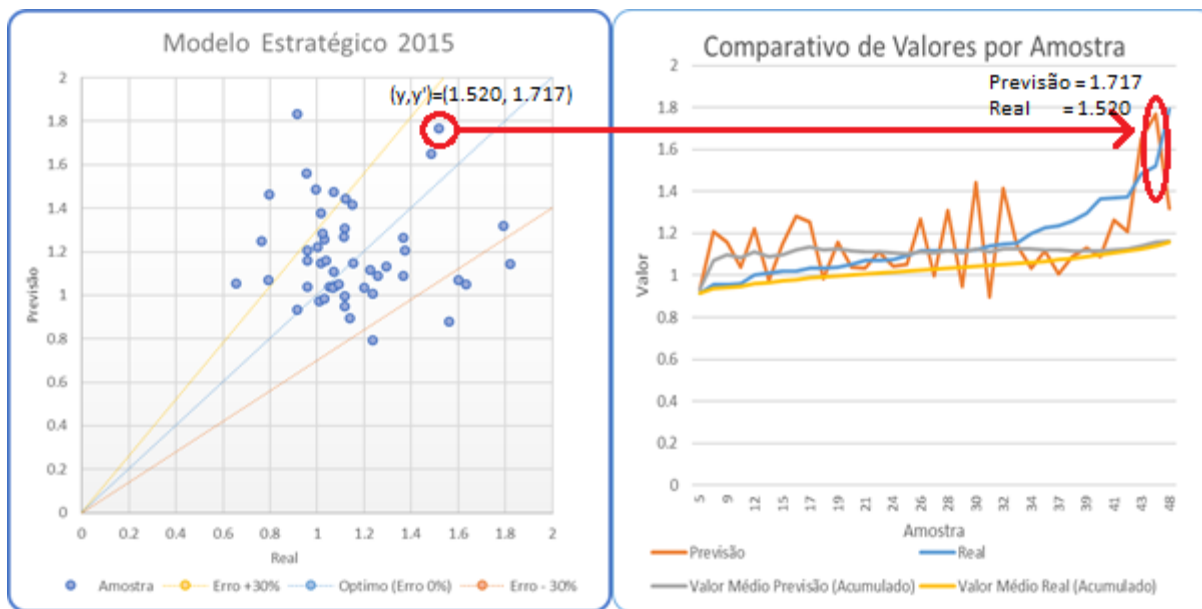


Figura 4.10: Exemplo: Relação entre gráficos de modelação

Note-se que no gráfico comparativo de valores por amostra as amostras estão filtradas por categoria de erro (<20%; <30% ou >30%).

### 4.3.3 Gráficos: Modelação do Conjunto Treino

Tal como foi feito para o conjunto de testes, também o conjunto de treino tem gráficos que permitem visualizar a forma como se comporta o modelo em relação ao conjunto que o serviu para criar.





Figura 4.11: Exemplo - Modelação do conj. de Treino. (Prev. vs Real)

A Figura 4.11 mostra a modelação de um conjunto treino. As amostras do conjunto treino devem-se encontrar sobre a diagonal  $y=y'$ , no entanto devido à natureza matemática do modelo, esta característica nem sempre pode estar inerente ao modelo. Se o modelo é matemático então também será determinístico e por isso não pode ter para a mesma parametrização duas imagens diferentes. O que significa que o modelo otimiza a possível saída, mas poderá induzir erros nos valores que lhe deram origem. Por exemplo se tivermos duas amostras onde  $(x_1=1, y_1=2)$  e  $(x_2=1, y_2=3)$  significa que se a aplicação da entrada do modelo for 1, a saída terá pelo menos sempre um erro referente, a pelo menos uma das amostras.

No entanto, a avaliação da capacidade de modelar o conjunto treino deverá ser tida em conta, uma vez que se o modelo foi incapaz de modelar o conjunto treino, com uma certa precisão, então o modelo não deve ser considerado um modelo com qualidade aceitável.

Analogamente, a relação com o que acontecia com o gráfico do modelo do conjunto treino (previsão vs real) e o gráfico comparativo de valores por amostra, como verificado na Figura 4.10, também acontece com os dois gráficos disponíveis para visualizar a modelação do conjunto teste.



*Figura 4.12: Exemplo - Modelação do conj. de Treino.*

Note-se que na Figura 4.12 os picos visíveis na função dos valores previstos (linha laranja) refletem os pontos mais distantes da linha diagonal da Figura 4.11, podendo ser analisados da mesma forma que foi demonstrado na Figura 4.10. A diferença é que neste gráfico todas as amostras do conjunto treino estão contempladas.

#### 4.3.4 Gráficos: Modelação RNAs vs Árvores de Decisão

Note-se que existe uma diferença na visualização dos gráficos dos modelos conseguidos pelas RNAs e os gráficos conseguidos pelas Árvores de Decisão.




Figura 4.13: Exemplo: Modelação do conj. de Teste. (Prev. vs Real) por Árvore de Decisão.




Figura 4.14: Exemplo. Modelação do conj. de Teste. (Prev. vs Real) por Rede Neuronal Artificial

Não existindo um interesse em focar na eficiência ou desempenho de cada um dos modelos, é fácil reparar que a visualização do gráfico relativo à árvore de decisão parece ter uma forma mais organizada das amostras do que no caso das redes neuronais artificiais.

É preciso entender que as árvores de decisão utilizadas consistiram na ramificação por categorias, o que significa que cada valor previsto tem um valor específico e discreto. No caso das redes neuronais artificiais cada valor previsto é calculado através de uma função contínua e por isso para cada amostra o cálculo do valor previsto através do modelo pode ter qualquer valor dentro de um intervalo.

Por este motivo é possível, que nas árvores de decisão, para amostras diferentes os valores previstos calculados sejam os mesmos, ou seja pertençam à mesma categoria, e a acontecer com um número elevado de amostras pode mesmo dar a sensação que faltam amostras. A verdade é que existem amostras com valores previstos sobrepostos.

Para as árvores de decisão o comparativo de valores por amostra reflete um efeito em escada entre cada categoria do valor real, como se pode verificar na Figura 4.15.




Figura 4.15: Exemplo: Comparativo de valores por amostra de Árvore de Decisão.




Figura 4.16: Exemplo: Comparativo de valores por amostra de RNAs

No entanto no caso do gráfico comparativo de valores por amostra das redes neuronais, como se pode verificar na Figura 4.16, esta característica não está presente. Isto deve-se ao facto de que para facilitar a visualização entre a transição das categorias dos valores previstos, as amostras do modelo das árvores de decisão foram ordenadas pelo valor real, tal como no modelo por redes neuronais, mas existiu uma segunda ordenação pelo valor previsto, coisa que para as redes neuronais não existiu.

### 4.3.5 Dados e resultados das amostras

A Figura 4.17 sobre o número de amostras reflete parcialmente a informação contida na Tabela 4-12




Figura 4.17: Exemplo - Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	30	21.127%	21.127%
$5\% \leq \epsilon < 10\%$	24	16.901%	38.028%
$10\% \leq \epsilon < 20\%$	32	22.535%	60.563%
$20\% \leq \epsilon < 30\%$	25	17.606%	78.169%
$30\% \leq \epsilon < 40\%$	11	7.746%	85.915%
$40\% \leq \epsilon < 50\%$	7	4.930%	90.845%
$\epsilon \geq 50\%$	13	9.155%	100.000%
Total	142	100%	

Tabela 4-12: Exemplo - Número e % de amostras por categoria de erro.

A Figura 4.17 e Tabela 4-12 indicam o número de amostras categorizadas por cada categoria de erro, este gráfico possibilita a visualização da distribuição dos erros da modelação consoante a categoria em que o erro se enquadra. Sendo que a tabela tem informação sobre o número acumulado de amostras que se encontram abaixo de determinada categoria de erro.

#### 4.3.6 Dados do Erro Médio e Amplitude dos Resultados do Modelo

Erro médio	Erro médio(%)		
0.210808605	20.60%		
	y	y'	Delta
max	1.855039239	1.622274	-12.55%
min	0.523596214	0.468489	10.52%

Tabela 4-13: Exemplo - Valor e % do erro médio e amplitude de resultados

A Tabela 4-13 reflete o erro médio absoluto e o erro médio relativo (%) das amostras do conjunto teste. Por esta tabela, também, é possível verificar os valores mínimos e máximos, quer dos valores reais quer dos valores previstos.

Sendo que o delta indica se o máximo e o mínimo dos valores previstos são maiores ou menores que os valores reais. Ou seja, permite inferir a amplitude dos valores modelados. Quando o delta é negativo então indica que o máximo ou o mínimo dos valores previstos têm menor amplitude que os valores reais.

No exemplo da Tabela 4-13, o erro médio absoluto é de 0.21 e o erro médio relativo é de 20.6%, sendo que o intervalo de valores reais é [0.5236, 1.8550] e o intervalo de valores previstos é [0.4685, 1.6223]. O que significa que o máximo dos valores previstos está abaixo cerca de 12.55% dos valores reais e o mínimo dos valores previstos está abaixo 10.52% dos valores reais. O delta positivo significa que os valores previstos são mais abrangentes que os valores reais, quer no mínimo quer no máximo.

Ficando os deltas definidos da seguinte forma:

$$\delta_{max} = \frac{(y_{max} - y'_{max})}{y_{max}} \quad (\text{Eq. 4.3})$$

$$\delta_{min} = \frac{(y'_{min} - y_{min})}{y_{min}} \quad (\text{Eq. 4.4})$$

A comparação da amplitude serve para verificar se o resultado dos valores previstos sai da faixa dos valores reais. Uma diferença significativa pode indicar uma qualidade baixa do modelo.



#### 4.3.7 Método de Avaliação dos Modelos

Após a descrição da avaliação gráfica, dos erros e a amplitude da modelação é possível descrever como e em que bases cada modelo, criado a partir de RNAs, vai ser avaliado em função dos resultados obtidos.

Neste estudo existem 5 princípios que determinam a qualidade dos modelos gerados. Esses princípios ficam definidos da seguinte forma:

- 1) Princípio de Modelação do Conjunto Treino: O conjunto treino tem de ser bem modelado, ou seja, a aplicação do vetor entrada do conjunto treino tem de conseguir prever com alguma precisão as saídas correspondentes. Devido à característica determinística dos modelos matemáticos a modelação num certo grau de precisão do conjunto treino pode ter algumas exceções. Um certo erro também é admissível, no caso deste estudo considera-se admissível um erro médio relativo máximo de 5%.
- 2) Princípio da Avaliação Gráfica: O comportamento da função de valores previstos tem de ser semelhante, num certo grau, ao comportamento dos valores reais. É importante tomar em consideração a natureza oscilatória da função de valores previstos.
- 3) Princípio do Erro Médio: O erro relativo médio não sendo a principal medida de qualidade do modelo, é importante que seja tomado em conta para a determinar. É uma forma simples de providenciar uma primeira avaliação para a qualidade do modelo. Neste estudo considera-se um erro médio admissível se for inferior a 25%.
- 4) Princípio do Erro por Conjunto de Amostras: Este princípio visa garantir que existe um número máximo de amostras que ultrapassa o erro médio. Neste estudo define-se como máximo 30% das amostras com um erro relativo superior a 30%, ou seja, que uma das premissas para ser considerado um modelo com qualidade mínima desejável que deve ter pelo menos 70% das amostras abaixo do erro relativo médio de 30%.
- 5) Princípio da Amplitude: A amplitude do conjunto de valores previstos pelo modelo tem de estar de acordo com a amplitude do conjunto de valores reais.

Isto significa que se as amplitudes diferirem muito, a modelação do ambiente pode não estar de acordo com o que é pretendido. Por exemplo, se a amplitude dos valores reais for 2 e a amplitude dos valores previstos for 0.5, ainda que o erro seja pequeno, o modelo gerado pode não ter capacidade de modelação do respetivo ambiente. Contudo uma avaliação mais precisa pode necessitar ser executada, por exemplo em modelos em que foi utilizado conjuntos treino restritos ou por exemplo, ambientes em que apenas um número reduzido possa estar fora dos limites pretendidos.

Para o princípio de avaliação gráfica, define-se como necessário que o conjunto das amostras com erro inferior a 30% tenha pelo menos a avaliação da comparação, da função de valores previstos com a função de valores reais, seja pelo menos de ligeiro. Com um erro admissível de 30% pode tornar-se difícil as semelhanças entre as funções. No entanto, para o conjunto das amostras com erro inferior a 20% essa semelhança já deverá ser visível pelo que se estipula que no mínimo a avaliação da comparação seja de pelo menos considerado médio.

O modelo de avaliação pode ser visualizado através do diagrama seguinte,

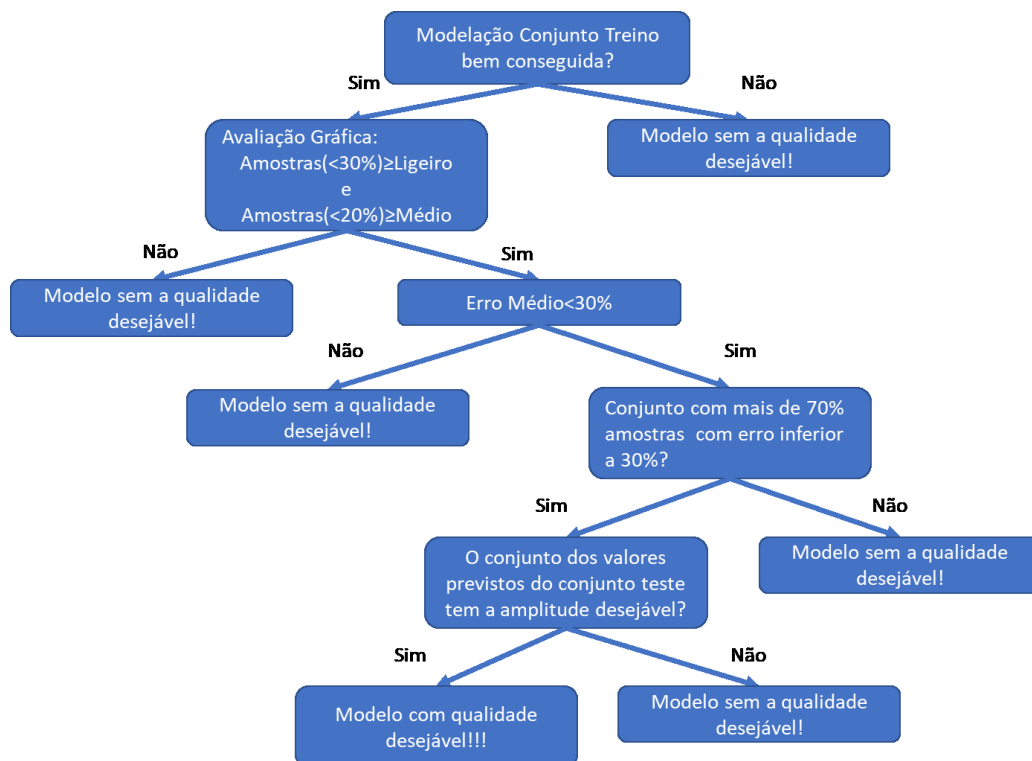


Figura 4.18: Diagrama do modelo de avaliação

#### 4.4 Previsão através de Redes Neurais

Nesta secção são apresentadas as hipóteses de observação inerentes ao estudo afeto a metodologia de redes neurais utilizada. É nesta secção que são apresentados os resultados obtidos por essa mesma metodologia.

##### 4.4.1 Hipóteses de Observação

Tal como referido na secção 4.1.3, o objetivo da hipótese é debruçar-se sobre a possibilidade de construir um modelo, utilizando RNAs que permitam a construção de um modelo de previsão de resultados através das estratégias utilizadas pelas organizações. Este modelo tem como entrada as estratégias a utilizar no respetivo ano. Como saídas deve produzir os resultados esperados pela utilização das estratégias definidas na entrada. Entenda-se por resultados esperados o rácio de variação entre o ano anterior e o respetivo ano

Os dados a serem utilizados são os descritos na secção 4.2. Os dados estão inerentes às particularidades descritas nessa mesma secção e os resultados analisados devem providenciar uma resposta sobre a possibilidade de criação de um modelo através de RNAs que permita o objetivo proposto.

Relembra-se mais uma vez que o estudo foca-se na possibilidade de construção e não na construção do próprio modelo. A construção do modelo inerente ao estudo está aliada à necessidade de o fazer para que se possa avaliar o desempenho do modelo e chegar a uma conclusão. Isto significa que embora a criação do modelo tenha sido alvo de um número elevado de experiências, a otimização das RNAs não foi feita de forma extensiva, mas apenas até se compreender se o modelo poderia ser construído com base nos pressupostos.

##### 4.4.2 Avaliação dos Resultados Gráficos

Nesta secção irão ser avaliados os gráficos “Comparativos de Valores por Amostra”, quer para o subconjunto das amostras com erro inferior a 30%, quer para o subconjunto das amostras com erro inferior a 20%, dos resultados obtidos através da modelação por redes neurais. É necessário realçar a importância extrema da avaliação destes gráficos, uma vez que são estes gráficos que permitem uma conclusão mais fidedigna da avaliação dos modelos, como já referido.

A forma como a avaliação foi executada está descrito na secção 4.3.1. Relembra-se que o objetivo desta avaliação é analisar o comportamento da função dos valores previstos e compará-lo com o

comportamento da função de valores reais. Não existe forma de fazê-lo de uma forma matemática uma vez que a função de valores previstos é desconhecida, apenas são conhecidos os valores de alguns pontos. Por isso a forma de comparação é feita visualmente. Visualmente pretende-se verificar se as funções seguem o mesmo comportamento, e considerar se este acompanhamento esta dentro de quatro categorias definidas:

- 1) Mau: Não se vislumbra graficamente qualquer acompanhamento
- 2) Ligeiro: Os valores previstos acompanham ligeiramente o comportamento dos valores reais
- 3) Médio: Os valores previstos acompanham o comportamento dos valores reais ainda que com uma margem de erro
- 4) Bom: Os valores previstos acompanham de forma facilmente identificável o comportamento dos valores reais

Isto significa que caso uma função de valores previstos se comporte de forma aleatória deve ser considerado um mau modelo do ambiente que se pretende modelar. Neste caso o comportamento da função dos valores previstos em comparação com a função de valores reais não se deve conseguir visualizar semelhanças. Para os outros três níveis (ligeiro, médio e bom) considera-se o nível possível de visualizar no acompanhamento feito pelas respetivas funções.

Note-se que existem 2 categorias de funções a ter em conta, as funções propriamente ditas, nomeadamente a função de valores previstos e a função de valores reais, e ainda, a funções dos valores médios ao longo das amostras ordenadas por valores reais. Desta forma pode perceber-se melhor o impacto das amostras nos limites do modelo.

Outro facto que se deve ter em atenção, é que deve ser dado mais ênfase às restrições dos valores previstos com um erro inferior a 20%. As funções dos valores previstos pertencentes a esta categoria devem verificar um acompanhamento melhor do que para o conjunto de erros inferiores a 30%. Neste sentido o mínimo aceitável para uma avaliação visual do conjunto de amostras com erro inferior a 20% é de “Médio”, enquanto para as amostras com um erro inferior a 30% é de “Ligeiro”.

A importância desta avaliação está inerente á decisão de julgar como insuficiente uma avaliação puramente baseada nos erros médios dados pela previsão através do modelo. Basear a avaliação

puramente através dos erros da previsão através do modelo poderia dar uma ideia incompleta e mesmo errada da sua performance.

### Neural Network Console

#### Modelo Estratégico 2013




Figura 4.19: ME13NC. Valores e médias por amostra c/erro<30%.




Figura 4.20: ME13NC. Valores e médias por amostra c/erro<20%.

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME13NC	Ligeiro	Médio

Tabela 4-14: ME13NC - Avaliação visual dos gráficos comparativos de valores por amostra

## Modelo Estratégico 2014




Figura 4.21: ME14NC. Valores e médias por amostra c/erro<30%.




Figura 4.22: ME14NC. Valores e médias por Amostra c/erro<20%.

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME14NC	Bom	Bom

Tabela 4-15: ME14NC - Avaliação visual dos gráficos comparativos de valores por amostra

## Modelo Estratégico 2015




Figura 4.23: ME15NC. Valores e médias por amostra c/erro<30%.




Figura 4.24: ME15NC. Valores e médias por Amostra c/erro<20%.

## ESTUDO EMPÍRICO

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME15NC	Mau	Ligeiro

Tabela 4-16: ME15NC - Avaliação visual dos gráficos comparativos de valores por amostra

### Modelo Estratégico Total 2013 – Conjunto de Avaliação 2014




Figura 4.25: ME13T14NC. Valores e médias por amostra c/erro<30%.




Figura 4.26: ME13T14NC. Valores e médias por Amostra c/erro<20%.

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME13T14NC	Ligeiro	Médio

Tabela 4-17: ME13T14NC - Avaliação visual dos gráficos comparativos de valores por amostra

Modelo Estratégico Total 2014 – Conjunto de Avaliação 2015




Figura 4.27: ME14T15NC. Valores e médias por amostra c/erro<30%.




Figura 4.28: ME14T15NC. Valores e médias por Amostra c/erro<20%.

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME14T15NC	Médio	Bom

Tabela 4-18: ME14T15NC - Avaliação visual dos gráficos comparativos de valores por amostra



**R CRAN**

Modelo Estratégico 2013

RProp-




Figura 4.29: ME13R (RProp-). Valores e médias por amostra c/erro<30%.




Figura 4.30: ME13R(RProp-). Valores e médias por Amostra c/erro<20%.

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME13R (Rprop-)	Ligeiro	Bom

Tabela 4-19: ME13R (RProp-) - Avaliação visual dos gráficos comparativos de valores por amostra

RProp+




Figura 4.31: ME13R (RProp+). Valores e médias por amostra c/erro<30%.




Figura 4.32: ME13R(RProp+). Valores e médias por amostra c/erro<20%

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME13R (Rprop+)	Mau	Ligeiro

Tabela 4-20: ME13R (RProp+) - Avaliação visual dos gráficos comparativos de valores por amostra

SAG




Figura 4.33: ME13R (SAG). Valores e médias por amostra c/erro<30%.




Figura 4.34: ME13R (SAG). Valores e médias por amostra c/erro<20%

## ESTUDO EMPÍRICO

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME13R (SAG)	Ligeiro	Bom

Tabela 4-21: ME13R (SAG) - Avaliação visual dos gráficos comparativos de valores por amostra

### RProp Avg




Figura 4.35: ME13R (AVG RProp). Valores e médias por amostra c/erro<30%.




Figura 4.36: ME13R (RProp Avg). Valores e médias por Amostra c/erro<20%.

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME13R (Rprop Avg)	Mau	Ligeiro

Tabela 4-22: ME13R (RProp Avg) - Avaliação visual dos gráficos comparativos de valores por amostra

AVG6




Figura 4.37: ME13R (AVG6). Valores e médias por amostra c/erro<30%.




Figura 4.38: ME13R (AVG6). Valores e médias por amostra c/erro<20%.

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME13R (AVG6)	Médio	Médio

Tabela 4-23: ME13R (AVG6) - Avaliação visual dos gráficos comparativos de valores por amostra

RProp-/Q




Figura 4.39: ME13R (RProp-/Q). Valores e médias por amostra c/erro<30%.




Figura 4.40: ME13R (RProp-/Q). Valores e médias por amostra c/erro<20%.

## ESTUDO EMPÍRICO

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME13R (Rprop-/Q)	Ligeiro	Bom

Tabela 4-24: ME13R (RProp-/Q) - Avaliação visual dos gráficos comparativos de valores por amostra

RProp+/Q




Figura 4.41: ME13R (RProp+/Q). Valores e médias por amostra c/erro<30%.




Figura 4.42: ME13R (RProp+/Q). Valores e médias por amostra c/erro<20%.

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME13R (Rprop+/Q)	Mau	Médio

Tabela 4-25: ME13R (RProp+/Q) - Avaliação visual dos gráficos comparativos de valores por amostra

SAG/Q




Figura 4.43: ME13R (SAG/Q). Valores e médias por amostra c/erro<30%.




Figura 4.44: ME13R (SAG/Q). Valores e médias por amostra c/erro<20%.

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME13R (SAG/Q)	Bom	Médio

Tabela 4-26: ME13R (SAG/Q) - Avaliação visual dos gráficos comparativos de valores por amostra

Modelo Estratégico 2014

RProp-




Figura 4.45: ME14R (RProp-). Valores e médias por amostra c/erro<30%.




Figura 4.46: ME14R (RProp-). Valores e médias por amostra c/erro<20%.

## ESTUDO EMPÍRICO

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME14R (Rprop-)	Mau	Ligeiro

Tabela 4-27: ME14R (RProp-) - Avaliação visual dos gráficos comparativos de valores por amostra

RProp+




Figura 4.47: ME14R (RProp+). Valores e médias por amostra c/erro<30%.




Figura 4.48: ME14R (RProp+). Valores e médias por amostra c/erro<20%

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME14R (Rprop+)	Ligeiro	Bom

Tabela 4-28: ME14R (RProp+) - Avaliação visual dos gráficos comparativos de valores por amostra

SAG




Figura 4.49: ME14R (SAG). Valores e médias por amostra c/erro<30%.




Figura 4.50: ME14R (SAG). Valores e médias por amostra c/erro<20%

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME14R (SAG)	Ligeiro	Médio

Tabela 4-29: ME14R (SAG) - Avaliação visual dos gráficos comparativos de valores por amostra

RProp Avg




Figura 4.51: ME14R (AVG RProp). Valores e médias por amostra c/erro<30%.




Figura 4.52: ME14R (RProp Avg). Valores e médias por amostra c/erro<20%



## ESTUDO EMPÍRICO

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME14R (Rprop Avg)	Mau	Médio

Tabela 4-30: ME14R (RProp Avg) - Avaliação visual dos gráficos comparativos de valores por amostra

### AVG6




Figura 4.53: ME14R (AVG6). Valores e médias por amostra c/erro<30%.




Figura 4.54: ME14R (AVG6). Valores e médias por Amostra c/erro<20%

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME14R (AVG6)	Ligeiro	Médio

Tabela 4-31: ME14R (AVG6) - Avaliação visual dos gráficos comparativos de valores por amostra

RProp-/Q




Figura 4.55: ME14R (RProp-/Q). Valores e médias por amostra c/erro<30%.




Figura 4.56: ME14R (RProp-/Q). Valores e médias por Amostra c/erro<20%

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME14R (Rprop-/Q)	Ligeiro	Médio

Tabela 4-32: ME14R (RProp-/Q) - Avaliação visual dos gráficos comparativos de valores por amostra

RProp+/Q




Figura 4.57: ME14R (RProp+/Q). Valores e médias por amostra c/erro<30%.




Figura 4.58: ME14R (RProp+/Q). Valores e médias por amostra c/erro<20%.

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME14R (Rprop+/Q)	Ligeiro	Médio

Tabela 4-33: ME14R (RProp+/Q) - Avaliação visual dos gráficos comparativos de valores por amostra

SAG/Q




Figura 4.59: ME14R (SAG/Q). Valores e médias por amostra c/erro<30%.




Figura 4.60: ME14R (SAG/Q). Valores e médias por amostra c/erro<20%.

## ESTUDO EMPÍRICO

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME14R (SAG/Q)	Ligeiro	Bom

Tabela 4-34: ME14R (SAG/Q) - Avaliação visual dos gráficos comparativos de valores por amostra

### Modelo Estratégico 2015

#### RProp-




Figura 4.61: ME15R (RProp-). Valores e médias por amostra c/erro<30%.




Figura 4.62: ME15R (RProp-). Valores e médias por amostra c/erro<20%

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME15R (Rprop-)	Ligeiro	Bom

Tabela 4-35: ME15R (RProp-) - Avaliação visual dos gráficos comparativos de valores por amostra

RProp+




Figura 4.63: ME15R (RProp+). Valores e médias por amostra c/erro<30%.




Figura 4.64: ME15R (RProp+). Valores e médias por amostra c/erro<20%

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME15R (Rprop+)	Ligeiro	Bom

Tabela 4-36: ME15R (RProp+) - Avaliação visual dos gráficos comparativos de valores por amostra

SAG




Figura 4.65: ME15R (SAG). Valores e médias por amostra c/erro<30%.




Figura 4.66: ME15R (SAG). Valores e médias por amostra c/erro<20%

## ESTUDO EMPÍRICO

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME15R (SAG)	Mau	Médio

Tabela 4-37: ME15R (SAG) - Avaliação visual dos gráficos comparativos de valores por amostra

### RProp Avg




Figura 4.67: ME15R (RProp Avg). Valores e médias por amostra c/erro<30%.




Figura 4.68: ME15R (RProp Avg). Valores e médias por Amostra c/erro<20%

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME15R (Rprop Avg)	Ligeiro	Médio

Tabela 4-38: ME15R (RProp Avg) - Avaliação visual dos gráficos comparativos de valores por amostra

AVG6




Figura 4.69: ME15R (AVG6). Valores e médias por amostra c/erro<30%.




Figura 4.70: ME15R (AVG6). Valores e médias por amostra c/erro<20%.

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME15R (AVG6)	Ligeiro	Bom

Tabela 4-39: ME15R (AVG6) - Avaliação visual dos gráficos comparativos de valores por amostra

RProp-/Q




Figura 4.71: ME15R (RProp-/Q). Valores e médias por amostra c/erro<30%.




Figura 4.72: ME15R (RProp-/Q). Valores e médias por amostra c/erro<20%.

## ESTUDO EMPÍRICO

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME15R (Rprop-/Q)	Mau	Mau

Tabela 4-40: ME15R (RProp-/Q) - Avaliação visual dos gráficos comparativos de valores por amostra

RProp+/Q




Figura 4.73: ME15R (RProp+/Q). Valores e médias por amostra c/erro<30%.




Figura 4.74: ME15R (RProp+/Q). Valores e médias por amostra c/erro<20%

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME15R (Rprop+/Q)	Ligeiro	Bom

Tabela 4-41: ME15R (RProp+/Q) - Avaliação visual dos gráficos comparativos de valores por amostra



SAG/Q




Figura 4.75: ME15R (SAG/Q). Valores e médias por amostra c/erro<30%.




Figura 4.76: ME15R (SAG/Q). Valores e médias por amostra c/erro<20%.

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME15R (SAG/Q)	Ligeiro	Médio

Tabela 4-42: ME15R (SAG/Q) - Avaliação visual dos gráficos comparativos de valores por amostra

## Modelo Estratégico 2013 – Conjunto de Teste 2014

RProp-




Figura 4.77: ME13T14R (RProp-). Valores e médias por amostra c/erro<30%.




Figura 4.78: ME13T14R (RProp-). Valores e médias por amostra c/erro<20%

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME13T14R (Rprop-)	Médio	Bom

Tabela 4-43: ME13T14R (RProp-) - Avaliação visual dos gráficos comparativos de valores por amostra

RProp+




Figura 4.79: ME13T14R (RProp+). Valores e médias por amostra c/erro<30%.




Figura 4.80: ME13T14R (RProp+). Valores e médias por amostra c/erro<20%.

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME13T14R (Rprop+)	Médio	Médio

Tabela 4-44: ME13T14R (RProp+) - Avaliação visual dos gráficos comparativos de valores por amostra

SAG




Figura 4.81: ME13T14R (SAG). Valores e médias por amostra c/erro<30%.




Figura 4.82: ME13T14R (SAG). Valores e médias por amostra c/erro<20%.

## ESTUDO EMPÍRICO

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME13T14R (SAG)	Médio	Bom

Tabela 4-45: ME13T14R (SAG) - Avaliação visual dos gráficos comparativos de valores por amostra

### RProp Avg




Figura 4.83: ME13T14R (RProp AVG). Valores e médias por amostra c/erro<30%.




Figura 4.84: ME13T14R (RProp Avg). Valores e médias por amostra c/erro<20%

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME13T14R (Rprop Avg)	Ligeiro	Médio

Tabela 4-46: ME13T14R (RProp Avg) - Avaliação visual dos gráficos comparativos de valores por amostra

AVG6




Figura 4.85: ME13T14R (AVG6). Valores e médias por amostra c/erro<30%.




Figura 4.86: ME13T14R (AVG6). Valores e médias por amostra c/erro<20%.

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME13T14R (AVG6)	Ligeiro	Bom

Tabela 4-47: ME13T14R (AVG6) - Avaliação visual dos gráficos comparativos de valores por amostra

RProp-/Q




Figura 4.87: ME13T14R (RProp-/Q). Valores e médias por amostra c/erro<30%.




Figura 4.88: ME13T14R (RProp-/Q). Valores e médias por amostra c/erro<20%.

## ESTUDO EMPÍRICO

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME13T14R (Rprop-/Q)	Médio	Bom

Tabela 4-48: ME13T14R (RProp-/Q) - Avaliação visual dos gráficos comparativos de valores por amostra

RProp+/Q




Figura 4.89: ME13T14R (RProp+/Q). Valores e médias por amostra c/erro<30%.




Figura 4.90: ME13T14R (RProp+/Q). Valores e médias por amostra c/erro<20%

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME13T14R (Rprop+/Q)	Ligeiro	Bom

Tabela 4-49: ME13T14R (RProp+/Q) - Avaliação visual dos gráficos comparativos de valores por amostra

SAG/Q




Figura 4.91: ME13T14R (SAG/Q). Valores e médias por amostra c/erro<30%.




Figura 4.92: ME13T14R (SAG/Q). Valores e médias por amostra c/erro<20%.

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME13T14R (SAG/Q)	Bom	Bom

Tabela 4-50: ME13T14R (SAG/Q) - Avaliação visual dos gráficos comparativos de valores por amostra

Modelo Estratégico 2014 – Conjunto de Teste 2015

RProp-




Figura 4.93: ME14T15R (RProp-). Valores e médias por amostra c/erro<30%.




Figura 4.94: ME14T15R (RProp-). Valores e médias por amostra c/erro<20%

## ESTUDO EMPÍRICO

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME14T15R (Rprop-)	Ligeiro	Bom

Tabela 4-51: ME14T15R (RProp-) - Avaliação visual dos gráficos comparativos de valores por amostra

RProp+




Figura 4.95: ME14T15R (RProp). Valores e médias por amostra c/erro<30%.




Figura 4.96: ME14T15R (RProp+). Valores e médias por amostra c/erro<20%

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME14T15R (Rprop+)	Ligeiro	Bom

Tabela 4-52: ME14T15R (RProp+) - Avaliação visual dos gráficos comparativos de valores por amostra



SAG




Figura 4.97: ME14T15R (SAG). Valores e médias por amostra c/erro<30%.




Figura 4.98: ME14T15R (SAG). Valores e médias por amostra c/erro<20%

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME14T15R (SAG)	Médio	Bom

Tabela 4-53: ME14T15R (SAG) - Avaliação visual dos gráficos comparativos de valores por amostra

RProp Avg




Figura 4.99: ME14T15R (RProp Avg). Valores e médias por amostra c/erro<30%.




Figura 4.100: ME14T15R (RProp Avg). Valores e médias por amostra c/erro<20%

## ESTUDO EMPÍRICO

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME14T15R (Rprop Avg)	Mau	Médio

Tabela 4-54: ME14T15R (RProp Avg) - Avaliação visual dos gráficos comparativos de valores por amostra

AVG6




Figura 4.101: ME14T15R (AVG6). Valores e médias por amostra c/erro<30%.




Figura 4.102: ME14T15R (AVG6). Valores e médias por amostra c/erro<20%

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME14T15R (AVG6)	Ligeiro	Bom

Tabela 4-55: ME14T15R (AVG6) - Avaliação visual dos gráficos comparativos de valores por amostra

RProp-/Q




Figura 4.103: ME14T15R (RProp-/Q). Valores e médias por amostra c/erro<30%.




Figura 4.104: ME14T15R (RProp-/Q). Valores e médias por amostra c/erro<20%

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME14T15R (Rprop-/Q)	Médio	Bom

Tabela 4-56: ME14T15R (RProp-/Q) - Avaliação visual dos gráficos comparativos de valores por amostra

RProp+/Q




Figura 4.105: ME14T15R (RProp+/Q). Valores e médias por amostra c/erro<30%.




Figura 4.106: ME14T15R (RProp+/Q). Valores e médias por amostra c/erro<20%

## ESTUDO EMPÍRICO

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME14T15R (Rprop+/Q)	Ligeiro	Bom

Tabela 4-57: ME14T15R (RProp+/Q) - Avaliação visual dos gráficos comparativos de valores por amostra

SAG/Q




Figura 4.107: ME14T15R (SAG/Q). Valores e médias por amostra c/erro<30%.




Figura 4.108: ME14T15R (SAG/Q). Valores e médias por amostra c/erro<20%

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME14T15R (SAG/Q)	Médio	Bom

Tabela 4-58: ME14T15R (SAG/Q) - Avaliação visual dos gráficos comparativos de valores por amostra

## Modelo Estratégico Global

## RProp-




Figura 4.109: MEGlobalR (RProp-). Valores e médias por amostra c/erro<30%.




Figura 4.110: MEGlobalR (RProp-). Valores e médias por amostra c/erro<20%.

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
MEGlobalR (Rprop-)	Médio	Bom

Tabela 4-59: MEGlobalR (RProp-) - Avaliação visual dos gráficos comparativos de valores por amostra

## RProp+




Figura 4.111: MEGlobalR (RProp+). Valores e médias por amostra c/erro<30%.




Figura 4.112: MEGlobalR (RProp+). Valores e médias por amostra c/erro<20%.

## ESTUDO EMPÍRICO

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
MEGlobalR (Rprop+)	Médio	Bom

Tabela 4-60: MEGlobalR (RProp+) - Avaliação visual dos gráficos comparativos de valores por amostra

### SAG




Figura 4.113: MEGlobalR (SAG). Valores e médias por amostra c/erro<30%.




Figura 4.114: MEGlobalR (SAG). Valores e médias por amostra c/erro<20%.

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
MEGlobalR (SAG)	Médio	Bom

Tabela 4-61: MEGlobalR (SAG) - Avaliação visual dos gráficos comparativos de valores por amostra

## RProp Avg




Figura 4.115: MEGlobalR (RProp Avg). Valores e médias por amostra c/erro<30%.




Figura 4.116: MEGlobalR (RProp Avg). Valores e médias por amostra c/erro<20%.

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
MEGlobalR (Rprop Avg)	Ligeiro	Bom

Tabela 4-62: MEGlobalR (RProp Avg) - Avaliação visual dos gráficos comparativos de valores por amostra

## AVG6




Figura 4.117: MEGlobalR (AVG6). Valores e médias por amostra c/erro<30%.




Figura 4.118: MEGlobalR (AVG6). Valores e médias por amostra c/erro<20%.

## ESTUDO EMPÍRICO

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
MEGlobalR (AVG6)	Médio	Bom

Tabela 4-63: MEGlobalR (AVG6) - Avaliação visual dos gráficos comparativos de valores por amostra

### RProp-/Q




Figura 4.119: MEGlobalR (RProp-/Q). Valores e médias por amostra c/erro<30%.




Figura 4.120: MEGlobalR (RProp-/Q). Valores e médias por amostra c/erro<20%

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
MEGlobalR (Rprop-/Q)	Ligeiro	Médio

Tabela 4-64: MEGlobalR (RProp-/Q) - Avaliação visual dos gráficos comparativos de valores por amostra



RProp+/Q




Figura 4.121: MEGlobalR (RProp+/Q). Valores e médias por amostra c/erro<30%.




Figura 4.122: MEGlobalR (RProp+/Q). Valores e médias por amostra c/erro<20%.

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
MEGlobalR (Rprop+/Q)	Médio	Bom

Tabela 4-65: MEGlobalR (RProp+/Q) - Avaliação visual dos gráficos comparativos de valores por amostra

SAG/Q




Figura 4.123: MEGlobalR (SAG/Q). Valores e médias por amostra c/erro<30%.




Figura 4.124: MEGlobalR (SAG/Q). Valores e médias por amostra c/erro<20%.

## ESTUDO EMPÍRICO

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
MEGlobalR (SAG/Q)	Ligeiro	Bom

Tabela 4-66: MEGlobalR (SAG/Q-) - Avaliação visual dos gráficos comparativos de valores por amostra

### 4.4.3 Análise dos Resultados obtidos

Nesta fase é executada uma avaliação final dos resultados obtidos pelos modelos gerados. Desta forma é possível identificar os modelos considerados como capazes de modelar o ambiente desejado.

A Tabela 4-67 tem todos os modelos gerados considerados como tendo uma modelação com sucesso face ao ambiente que se pretende modelar. Neste caso os valores previstos estão conforme os 5 princípios definidos e não existe uma necessidade de uma análise mais detalhada do que aquela que já foi executada.

Modelo	Avaliação		Número de Amostras		% de Amostras		Amplitude (Delta)		Erro	
	Amostras com erro<30%	Amostras com erro<20%	$\epsilon < 30\%$	Total	$\epsilon < 20\%$	$\epsilon < 30\%$	max	min	Médio (%)	Avaliação Modelo
ME13NC	Ligeiro	Médio	27	38	50.00%	71.05%	-7.59%	8.99%	22.91%	Sucesso
ME13T14NC	Ligeiro	Médio	140	178	62.92%	78.65%	-9.81%	-15.68%	19.78%	Sucesso
ME14T15NC	Médio	Bom	132	166	69.88%	79.52%	0.76%	7.49%	17.90%	Sucesso
ME13R (Rprop-)	Ligeiro	Bom	29	38	52.63%	76.32%	9.06%	16.65%	21.52%	Sucesso
ME13R (AVG6)	Médio	Médio	28	38	63.16%	73.68%	-19.39%	3.20%	21.22%	Sucesso
ME13R (Rprop-/Q)	Ligeiro	Bom	32	38	57.90%	84.21%	-24.08%	4.32%	18.65%	Sucesso
ME13R (SAG/Q)	Bom	Médio	30	38	47.37%	78.95%	-20.24%	9.51%	22.44%	Sucesso
ME14R (Rprop+)	Ligeiro	Bom	61	73	65.75%	83.56%	9.76%	-7.47%	19.32%	Sucesso
ME14R (Rprop-/Q)	Ligeiro	Médio	54	73	54.80%	73.97%	20.44%	7.87%	24.87%	Sucesso
ME14R (Rprop+/Q)	Ligeiro	Médio	57	73	63.01%	78.08%	-0.28%	18.67%	19.41%	Sucesso
ME15R (Rprop-)	Ligeiro	Bom	38	49	55.10%	77.55%	6.95%	-15.60%	20.02%	Sucesso
ME15R (Rprop+)	Ligeiro	Bom	37	49	51.02%	75.51%	-10.92%	1.62%	21.81%	Sucesso
ME15R (Rprop Avg)	Ligeiro	Médio	37	49	69.39%	75.51%	-24.12%	-7.14%	16.32%	Sucesso
ME15R (AVG6)	Ligeiro	Bom	35	49	46.94%	71.43%	1.55%	-15.81%	23.40%	Sucesso
ME15R (Rprop+/Q)	Ligeiro	Bom	35	49	51.02%	71.43%	0.54%	-21.14%	24.12%	Sucesso
ME15R (SAG/Q)	Ligeiro	Médio	36	49	48.98%	73.47%	4.95%	-6.15%	22.70%	Sucesso
ME13T14R (Rprop+)	Médio	Médio	140	178	64.05%	78.65%	2.05%	-2.48%	21.20%	Sucesso
ME13T14R (Rprop Avg)	Ligeiro	Médio	139	178	58.99%	78.09%	-4.03%	-27.23%	20.40%	Sucesso
ME13T14R (Rprop-/Q)	Médio	Bom	140	178	60.11%	78.65%	-6.96%	1.94%	21.26%	Sucesso
ME13T14R (Rprop+/Q)	Ligeiro	Bom	142	178	63.48%	79.78%	-1.69%	-8.24%	20.39%	Sucesso
ME13T14R (SAG/Q)	Bom	Bom	133	178	63.48%	74.72%	-6.60%	-17.17%	20.20%	Sucesso

## ESTUDO EMPÍRICO

Modelo	Avaliação		Número de Amostras		% de Amostras		Amplitude (Delta)		Erro	
	Amostras com erro<30%	Amostras com erro<20%	$\epsilon < 30\%$	Total	$\epsilon < 20\%$	$\epsilon < 30\%$	max	min	Médio (%)	Avaliação Modelo
ME14T15R (Rprop+)	Ligeiro	Bom	128	166	58.43%	77.11%	5.30%	-5.93%	21.56%	Sucesso
ME14T15R (AVG6)	Ligeiro	Bom	134	166	68.07%	80.72%	-5.99%	-19.28%	18.98%	Sucesso
ME14T15R (Rprop-/Q)	Médio	Bom	134	166	60.84%	80.72%	-0.67%	-5.66%	19.83%	Sucesso
ME14T15R (SAG/Q)	Médio	Bom	131	166	65.66%	78.92%	-4.27%	5.20%	19.12%	Sucesso
MEGlobalR (Rprop-)	Médio	Bom	108	142	59.86%	76.06%	3.10%	25.29%	20.40%	Sucesso
MEGlobalR (Rprop+)	Médio	Bom	111	142	60.56%	78.17%	-12.55%	10.52%	20.60%	Sucesso
MEGlobalR (Rprop Avg)	Ligeiro	Bom	112	142	62.68%	78.87%	-4.12%	5.21%	19.08%	Sucesso
MEGlobalR (Rprop-/Q)	Ligeiro	Médio	103	142	57.75%	72.54%	19.77%	-4.01%	24.79%	Sucesso

*Tabela 4-67: Avaliação global dos modelos com sucesso (RNAs).*

A Tabela 4-68 mostra todos os modelos considerados sem sucesso. Todos os modelos aqui referenciados são modelos que não modelam o ambiente desejado de forma satisfatória e que não necessitam de uma análise mais detalhada.

Modelo	Avaliação		Numero de Amostras		% de Amostras		Amplitude (Delta)		Erro	
	Amostras com erro<30%	Amostras com erro<20%	$\epsilon < 30\%$	Total	$\epsilon < 20\%$	$\epsilon < 30\%$	max	min	Médio (%)	Avaliação Modelo
ME15NC	Mau	Ligeiro	36	49	55.10%	73.47%	-14.58%	-13.78%	19.30%	KO: Avaliação Gráfica
ME13R (Rprop+)	Mau	Ligeiro	32	38	63.16%	84.21%	14.93%	-2.66%	23.82%	KO: Avaliação Gráfica
ME13R (Rprop Avg)	Mau	Ligeiro	33	38	65.79%	86.84%	-20.99%	-3.20%	20.30%	KO: Avaliação Gráfica
ME13R (Rprop+/Q)	Mau	Médio	30	38	63.16%	78.95%	-8.18%	41.54%	21.38%	KO: Avaliação Gráfica
ME14R (Rprop-)	Mau	Ligeiro	65	73	69.86%	89.04%	-17.84%	-35.80%	16.69%	KO: Avaliação Gráfica
ME14R (Rprop Avg)	Mau	Médio	62	73	67.12%	84.93%	-11.28%	-28.70%	17.78%	KO: Avaliação Gráfica
ME15R (SAG)	Mau	Médio	29	49	40.82%	59.18%	28.40%	44.71%	28.40%	KO: Avaliação Gráfica
ME15R (Rprop-/Q)	Mau	Mau	36	49	51.02%	73.47%	57.54%	-37.88%	23.84%	KO: Avaliação Gráfica
ME14T15R (Rprop Avg)	Mau	Médio	145	166	71.08%	87.35%	-12.03%	-29.62%	17.18%	KO: Avaliação Gráfica
MEGlobalR (Rprop+/Q)	Médio	Bom	99	142	49.30%	69.72%	-9.48%	26.66%	25.82%	KO: Erro Conj. Amostras

*Tabela 4-68: Avaliação global dos modelos sem sucesso (RNAs)*

Note-se que todos os modelos referenciados na Tabela 4-68, á exceção do modelo MEGlobalR (RProp+/Q), indicam que a avaliação gráfica não foi satisfatória. Lembra-se que esta avaliação permite comparar o comportamento da função de valores previstos com a função de valores reais. Desta forma se as funções não mostram ter um comportamento semelhante, independentemente

da avaliação do erro médio ou que 70% do número de amostras do conjunto teste tem um erro inferior a 30%, não providenciam um modelo com a qualidade desejável.

O modelo MEGlobalR (RProp+/Q) falha no princípio que requer que 70% das amostras do conjunto teste tenham um erro inferior a 30%, apesar de ter 69,72% das amostras com um erro inferior ao desejável.

Na Tabela 4-69 estão referenciados todos os modelos que requerem uma análise mais detalhada. Esta análise mais detalhada é necessária no âmbito referido do princípio de amplitude na secção 4.3.7.

Modelo	Avaliação		Número de Amostras		% de Amostras		Amplitude (Delta)		Erro	
	Amostras com erro<30%	Amostras com erro<20%	$\epsilon < 30\%$	Total	$\epsilon < 20\%$	$\epsilon < 30\%$	max	min	Médio (%)	Avaliação Modelo
ME14NC	Bom	Bom	61	73	71.23%	83.56%	10.24%	-31.77%	16.85%	KO: Amplitude
ME13R (SAG)	Ligeiro	Bom	28	38	55.26%	73.68%	11.49%	32.17%	24.32%	KO: Amplitude
ME14R (SAG)	Ligeiro	Médio	54	73	57.53%	73.97%	24.16%	61.76%	22.87%	KO: Amplitude
ME14R (AVG6)	Ligeiro	Médio	60	73	61.64%	82.19%	-6.26%	30.67%	21.02%	KO: Amplitude
ME14R (SAG/Q)	Ligeiro	Bom	58	73	69.86%	79.45%	3.14%	66.50%	21.33%	KO: Amplitude
ME13T14R (Rprop-)	Médio	Bom	126	178	52.25%	70.79%	31.54%	40.44%	24.85%	KO: Amplitude
ME13T14R (SAG)	Médio	Bom	137	178	56.74%	76.97%	34.54%	-26.90%	21.83%	KO: Amplitude
ME13T14R (AVG6)	Ligeiro	Bom	142	178	65.73%	79.78%	1.62%	-34.14%	20.29%	KO: Amplitude
ME14T15R (Rprop-)	Ligeiro	Bom	126	166	57.83%	75.90%	9.61%	75.90%	21.54%	KO: Amplitude
ME14T15R (SAG)	Médio	Bom	128	166	63.25%	77.11%	33.75%	-1.55%	20.83%	KO: Amplitude
ME14T15R (Rprop+/Q)	Ligeiro	Bom	130	166	61.45%	78.31%	-2.97%	38.67%	21.59%	KO: Amplitude
MEGlobalR (SAG)	Médio	Bom	103	142	56.34%	72.54%	55.44%	67.89%	24.75%	KO: Amplitude
MEGlobalR (AVG6)	Médio	Bom	106	142	59.16%	74.65%	-4.08%	49.46%	21.05%	KO: Amplitude
MEGlobalR (SAG/Q)	Ligeiro	Bom	106	142	57.75%	74.65%	-14.38%	100.29%	21.61%	KO: Amplitude

Tabela 4-69: Avaliação global dos modelos passíveis de avaliação mais detalhada (RNAs)

Para executar uma avaliação mais detalhada dos modelos que falham numa primeira fase o princípio da amplitude foi criada a Tabela 4-70.

			Limites Admissíveis		#Amostras Y'			%Amostras Y'		#Amostras Y		%Amostras Y	
Modelo	Delta Max	Delta Min	Max Y + 30%	Min Y - 30%	#Total	> Max Y + 30%	< Min Y - 30%	> Max Y + 30%	< Min Y - 30%	> Max Y'	< Min Y'	> Max Y'	< Min Y'
ME14NC	10.24%	-31.77%	2.273	0.394	73	0	0	0.00%	0.00%	0	2	0.00%	2.74%

# ESTUDO EMPÍRICO

Modelo	Delta Max	Delta Min	Limites Admissíveis		#Amostras Y'			%Amostras Y'		#Amostras Y		%Amostras Y	
			Max Y + 30%	Min Y - 30%	#Total	> Max Y + 30%	< Min Y - 30%	> Max Y + 30%	< Min Y - 30%	> Max Y'	< Min Y'	> Max Y'	< Min Y'
ME13R (SAG)	11.49%	32.17%	2.460	0.541	38	0	1	0.00%	2.63%	0	0	0.00%	0.00%
ME14R (AVG6)	-6.26%	30.67%	2.273	0.394	73	0	1	0.00%	1.37%	2	0	2.74%	0.00%
ME14R (SAG/Q)	3.14%	66.50%	2.273	0.394	73	0	1	0.00%	1.37%	0	0	0.00%	0.00%
ME13T14R (RProp-)	31.54%	40.44%	2.552	0.367	178	1	1	0.56%	0.56%	0	0	0.00%	0.00%
ME13T14R (SAG)	34.54%	-26.90%	2.552	0.367	178	1	0	0.56%	0.00%	0	5	0.00%	2.81%
ME13T14R (AVG6)	1.62%	-34.14%	2.552	0.367	178	0	0	0.00%	0.00%	0	5	0.00%	2.81%
ME14T15R (SAG)	33.75%	-1.55%	2.493	0.420	166	1	0	0.60%	0.00%	0	1	0.00%	0.60%
ME14T15R (RProp+/Q)	-2.97%	38.67%	2.493	0.420	166	0	2	0.00%	1.20%	2	0	1.20%	0.00%
MEGlobalR (SAG)	55.44%	67.89%	2.412	0.367	142	1	2	0.70%	1.41%	0	0	0.00%	0.00%
MEGlobalR (AVG6)	-4.08%	49.46%	2.412	0.367	142	0	3	0.00%	2.11%	1	0	0.70%	0.00%
MEGlobalR (SAG/Q)	-14.38%	100.29%	2.552	0.401	142	0	1	0.00%	0.70%	12	0	8.45%	0.00%

Tabela 4-70: Avaliação dos modelos (Princípio da Amplitude) (RNAs)

De forma a avaliar corretamente a Tabela 4-70 é necessário seguir algumas diretrizes:

- 1) Preferencialmente o delta deve ser positivo. Isto é, a diferença de um delta igual a 15% significa que o modelo tem um intervalo mais abrangente que o intervalo do conjunto de valores reais, enquanto um delta de -15% significa que o intervalo do conjunto de valores previstos é mais restrito.
- 2) O número de amostras, que estão fora dos limites admissíveis em relação ao total, é importante do ponto de vista em aceitar um modelo como que com qualidade desejável.

A respetiva tabela contém a seguinte informação:

- 1) Delta Max e Delta Min: Os deltas associados à diferença entre o máximo e mínimo, respetivamente, entre os intervalos do conjunto de valores previstos e do conjunto de valores reais.
- 2) Limites Admissíveis: O intervalo considerado admissível para o conjunto de valores previstos.
- 3) Número de Amostras Y' (valores previstos):
  - a. Total
  - b. > Max Y + 30%: Reflete o número de amostras em que os valores previstos ultrapassam o limite do valor máximo.

- c.  $< \text{Min } Y - 30\%$ : Reflete o número de amostras em que os valores previstos são inferiores ao limite do valor mínimo.
- 4) % de Amostras Y' (valores previstos):
  - a.  $> \text{Max } Y + 30\%$ : Reflete a percentagem de amostras em que os valores previstos ultrapassam o limite do valor máximo.
  - b.  $< \text{Min } Y - 30\%$ : Reflete a percentagem de amostras em que os valores previstos são inferiores ao limite do valor mínimo.
- 5) Número de Amostras Y (valores reais):
  - a. Total
  - b.  $> \text{Max } Y$ : Reflete o número de amostras em que os valores reais ultrapassam o limite do máximo dos valores previstos. Ou seja, amostras que não se refletem no intervalo dos valores previstos.
  - c.  $< \text{Min } Y$ : Reflete o número de amostras em que os valores reais que são inferiores ao limite do mínimo dos valores previstos. Ou seja, amostras que não se refletem no intervalo dos valores previstos.
- 6) % de Amostras Y (valores reais):
  - a.  $> \text{Max } Y$ : Reflete a percentagem de amostras em que os valores reais ultrapassam o limite do máximo dos valores previstos. Ou seja, amostras que não se refletem no intervalo dos valores previstos.
  - b.  $< \text{Min } Y$ : Reflete a percentagem de amostras em que os valores reais que são inferiores ao limite do mínimo dos valores previstos. Ou seja, amostras que não se refletem no intervalo dos valores previstos.

Na análise da Tabela 4-70 é notório que os modelos que não se enquadram no princípio da amplitude, têm todos, com exceção do modelo MEGlobalR (SAG/Q), um número inferior a 3% das amostras que não respeitam o princípio da amplitude, independentemente se não é respeitado porque os valores previstos estão fora do intervalo admissível ou se é porque os valores reais se encontram fora do intervalo dos valores previstos.

Quanto ao modelo MEGlobalR (SAG/Q), o facto de mais de 8% das amostras terem os valores reais fora do intervalo definido pelos valores previstos, é fator para evidenciar que o modelo não tem a qualidade desejável para simular o ambiente pretendido.

Neste sentido é apresentado um exemplo de um modelo que executa uma modelação aceitável do ambiente pretendido:

Modelo	Avaliação		Numero de Amostras		% de Amostras		Amplitude (Delta)		Erro
	Amostras com erro<30%	Amostras com erro<20%	$\epsilon < 30\%$	Total	$\epsilon < 20\%$	$\epsilon < 30\%$	max	min	Médio (%)
ME13T14R (Rprop-/Q)	Médio	Bom	140	178	60.11%	78.65%	-6.96%	1.94%	21.26%

Tabela 4-71: Avaliação ME13T14 (RProp+/Q) - Exemplo de um modelo aceite




Figura 4.125: ME13T14R (RPro-/Q). Valores e médias por amostra c/erro<30%. - Exemplo de um modelo aceite.




Figura 4.126: ME13T14R (RProp-/Q). Modelação do conj. de Teste. (Prev. vs Real) - Exemplo de um modelo aceite




Figura 4.127: ME13T14R (RProp-/Q). Valores e médias por Amostra c/erro<20% - Exemplo de um modelo aceite




Figura 4.128: ME13T14R (RProp-/Q). Modelação do conj. de Treino. (Prev. vs Real) - Exemplo de um modelo aceite




Figura 4.129: ME13T14R (RProp-/Q). Valores por amostra c/erro>30%

Como se pode verificar pela Figura 4.128, o modelo do conjunto treino está bem formado, com os pontos a incidirem praticamente sobre a diagonal. A Figura 4.125 e Figura 4.127 mostram o comportamento das funções de valores previstos e reais e verifica-se que exceto o facto da função de valores previstos ter comportamento ondulatório este é semelhante ao comportamento da função de valores reais. Um erro médio de 21,26% e 78.65% das amostras com um erro inferior a 30%, incluindo cerca de 60% das amostras com um erro inferior a 20%. Inclusive a função dos valores previstos com erro superior a 30% tende a acompanhar o comportamento da função de valores reais.



## 4.5 Previsão através de Árvores de Decisão

Nesta secção são apresentadas as hipóteses de observação inerentes ao estudo afeto a metodologia de árvores de decisão utilizada. É nesta secção que são apresentados os resultados obtidos por essa mesma metodologia.

### 4.5.1 Hipóteses de Observação

A hipótese de observação que está inerente a esta secção prende-se com a necessidade de provar a possibilidade de modelar um ambiente estratégico a partir da metodologia baseada em árvores de decisão. O modelo estratégico deve permitir a previsão de resultados financeiros através das estratégias aplicadas em determinada organização.

A capacidade de previsão está limitada por uma precisão associada ao modelo, isto é a hipótese de observação é a possibilidade de construção do modelo e não de construir o modelo ótimo, isto significa que o estudo a ser executado irá debruçar-se sobre a qualidade dos modelos, mas apenas como prova de ser possível a modelação através da metodologia referida.

Este modelo tem como entrada as estratégias a utilizar no respetivo ano. Como saídas deve produzir os resultados esperados pela utilização das estratégias definidas na entrada. Entenda-se por resultados esperados o rácio de variação entre o ano anterior e o respetivo ano.

Os dados a serem utilizados são os descritos na secção 4.2. Os dados estão inerentes às particularidades descritas nessa mesma secção e os resultados analisados devem providenciar uma resposta sobre a possibilidade de criação de um modelo através de árvores de decisão que permitam o objetivo proposto.

Foca-se ainda o facto que às árvores de decisão pretendidas estão classificadas como árvores de decisão categóricas, pelo que o tratamento dos dados na categorização dos dados financeiros deve ser alvo de uma especial atenção.

### 4.5.2 Avaliação dos Resultados Gráficos

Tal como feito para a secção 4.4.2, relembra-se a importância e o objetivo da avaliação gráfica do comportamento da função dos valores previstos comparativamente à função dos valores reais.

Nesta secção irão ser avaliados os gráficos “Comparativos de Valores por Amostra”, quer para o subconjunto das amostras com erro inferior a 30%, quer para o subconjunto das amostras com erro

inferior a 20%, dos resultados obtidos através da modelação por árvores de decisão. É necessário realçar a importância extrema da avaliação destes gráficos, uma vez que são estes gráficos que permitem uma conclusão mais fidedigna da avaliação dos modelos, como já referido.

A forma como a avaliação foi executada está descrito na secção 4.3.1. Relembra-se que o objetivo desta avaliação é analisar o comportamento da função dos valores previstos e compará-lo com o comportamento da função de valores reais. Não existe forma de fazê-lo de uma forma matemática uma vez que a função de valores previstos é desconhecida, apenas são conhecidos os valores de alguns pontos. Por isso a forma de comparação é feita visualmente. Visualmente pretende-se verificar se as funções seguem o mesmo comportamento, e considerar se este acompanhamento esta dentro de quatro categorias definidas:

- 1) Mau: Não se vislumbra graficamente qualquer acompanhamento
- 2) Ligeiro: Os valores previstos acompanham ligeiramente o comportamento dos valores reais
- 3) Médio: Os valores previstos acompanham o comportamento dos valores reais ainda que com uma margem de erro
- 4) Bom: Os valores previstos acompanham de forma facilmente identificável o comportamento dos valores reais

Isto significa que caso uma função de valores previstos se comporte de forma aleatória deve ser considerado um mau modelo do ambiente que se pretende modelar. Neste caso o comportamento da função dos valores previstos em comparação com a função de valores reais não se deve conseguir visualizar semelhanças. Para os outros três níveis (ligeiro, médio e bom) considera-se o nível possível de visualizar no acompanhamento feito pelas respetivas funções.

Note-se que existem 2 categorias de funções a ter em conta, as funções propriamente ditas, nomeadamente a função de valores previstos e a função de valores reais, e ainda, a funções dos valores médios ao longo das amostras ordenadas primariamente pelos valores reais e secundariamente pelos valores previstos. Desta forma pode perceber-se melhor o impacto das amostras nos limites do modelo.

Outro facto que se deve ter em atenção, é que deve ser dado mais ênfase às restrições dos valores previstos com um erro inferior a 20%. As funções dos valores previstos pertencentes a esta

categoria devem verificar um acompanhamento melhor do que para o conjunto de erros inferiores a 30%. Neste sentido o mínimo aceitável para uma avaliação visual do conjunto de amostras com erro inferior a 20% é de “Médio”, enquanto para as amostras com um erro inferior a 30% é de “Ligeiro”.

A importância desta avaliação está inerente à decisão de julgar como insuficiente uma avaliação puramente baseada nos erros médios dados pela previsão através do modelo. Basear a avaliação puramente através dos erros da previsão através do modelo poderia dar uma ideia incompleta e mesmo errada da sua performance.

### Modelo Estratégico 2013




Figura 4.130: ME13ADR. Valores e médias por amostra c/erro<30%.




Figura 4.131: ME13ADR. Valores e médias por amostra c/erro<20%

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME13ADR	Médio	Bom

Tabela 4-72: ME13ADR - Avaliação visual dos gráficos comparativos de valores por amostra

### Modelo Estratégico 2014




Figura 4.132: ME14ADR. Valores e médias por amostra c/erro<30%.




Figura 4.133: ME14ADR. Valores e médias por amostra c/erro<20%.

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME14ADR	Ligeiro	Bom

Tabela 4-73: ME14ADR - Avaliação visual dos gráficos comparativos de valores por amostra

### Modelo Estratégico 2015




Figura 4.134: ME15ADR. Valores e médias por amostra c/erro<30%.




Figura 4.135: ME15ADR. Valores e médias por amostra c/erro<20%.

## ESTUDO EMPÍRICO

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME15ADR	Ligeiro	Médio

Tabela 4-74: ME15ADR - Avaliação visual dos gráficos comparativos de valores por amostra

### Modelo Estratégico 2013 – Conjunto Teste 2014




Figura 4.136: ME13T14ADR. Valores e médias por amostra c/erro<30%.




Figura 4.137: ME13T14ADR. Valores e médias por amostra c/erro<20%.

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME13T14ADR	Médio	Médio

Tabela 4-75: ME13T14ADR - Avaliação visual dos gráficos comparativos de valores por amostra

**Modelo Estratégico 2014 – Conjunto Teste 2015**




Figura 4.138: ME14T15ADR. Valores e médias por amostra c/erro<30%.




Figura 4.139: ME14T15ADR. Valores e médias por amostra c/erro<20%.

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
ME14T15ADR	Médio	Bom

Tabela 4-76: ME14T15ADR - Avaliação visual dos gráficos comparativos de valores por amostra

**Modelo Estratégico Global**




Figura 4.140: MEGlobalADR. Valores e médias por amostra c/erro<30%.




Figura 4.141: MEGlobalADR. Valores e médias por amostra c/erro<20%.

Modelo	Avaliação	
	Amostras com erro<30%	Amostras com erro<20%
MEGlobalADR	Bom	Bom

Tabela 4-77: MEGlobalADR - Avaliação visual dos gráficos comparativos de valores por amostra

### 4.5.3 Análise dos Resultados obtidos

Nesta secção analisa-se e discute-se os resultados obtidos pelos modelos gerados a partir da metodologia de árvores de decisão. Apresenta-se na Tabela 4-78 os resultados dos 5 princípios definidos para se considerar uma modelação com a qualidade aceitável.

Modelo	Avaliação		Número de Amostras		% de Amostras		Amplitude (Delta)		Erro	
	Amostras com erro<30%	Amostras com erro<20%	$\epsilon < 30\%$	Total	$\epsilon < 20\%$	$\epsilon < 30\%$	max	min	Médio (%)	Avaliação Modelo
ME13ADR	Médio	Bom	29	38	55.26%	76.32%	0.00%	-13.33%	20.25%	Sucesso
ME14ADR	Ligeiro	Bom	53	73	50.69%	72.60%	14.29%	9.09%	23.30%	Sucesso
ME15ADR	Ligeiro	Médio	37	49	55.10%	75.51%	2.78%	15.38%	20.42%	Sucesso
ME13T14ADR	Médio	Médio	134	178	60.67%	75.28%	2.56%	10.00%	21.99%	Sucesso
ME14T15ADR	Médio	Bom	125	166	63.86%	75.30%	-2.63%	-8.33%	20.96%	Sucesso
MEGlobalADR	Bom	Bom	100	142	52.82%	70.42%	-2.70%	20.00%	23.17%	Sucesso

Tabela 4-78: Avaliação global dos modelos gerados por ADs.

Como se pode verificar todos os modelos gerados com a metodologia de árvores de decisão mostraram ter uma qualidade aceitável como modelos estratégicos. Ao avaliar os gráficos referentes à secção 4.5.2 percebe-se da dificuldade de categorização das amostras com valores reais mais elevados. Esta situação pode dever-se ao número reduzido das amostras do conjunto treino que estão inseridos neste intervalo, e que levam o algoritmo a categorizar amostras dentro desse âmbito a serem categorizadas em categorias mais baixas.

Um ponto a ter em consideração é que todos os modelos tiveram resultados da avaliação muito semelhantes o que pode significar uma coerência significativa entre os modelos gerados por esta metodologia.

#### 4.6 Análise Comparativa dos Resultados

Nesta secção discute-se os resultados de forma comparativa entre a metodologia das RNAs e das ADs. Para fazer essa comparação escolhe-se a RNA de cada um dos modelos e plataforma que se julga ser o que melhor modela o ambiente desejado. Desta forma é possível comparar os modelos um a um, inclusive entre plataformas.

##### 4.6.1 Modelo Estratégico 2013

O Modelo Estratégico 2013 (ME13), é modelado utilizando 70% do conjunto dos dados do ano de 2013 para o conjunto treino. Para o conjunto de avaliação são utilizados os restantes 30% do conjunto dos dados do ano de 2013. E necessário referir que o conjunto de treino e o conjunto de teste são mutuamente exclusivos.

Modelo	Avaliação		Número de Amostras		% de Amostras		Amplitude (Delta)		Erro	Avaliação Modelo
	Amostras com erro<30%	Amostras com erro<20%	$\epsilon < 30\%$	Total	$\epsilon < 20\%$	$\epsilon < 30\%$	max	min	Médio (%)	
ME13NC	Ligeiro	Médio	27	38	50.00%	71.05%	7.59%	-8.99%	22.91%	Sucesso
ME13R (Rprop-/Q)	Ligeiro	Bom	32	38	<b>57.90%</b>	<b>84.21%</b>	24.08%	-4.32%	<b>18.65%</b>	Sucesso
ME13ADR	Médio	Bom	29	38	<b>55.26%</b>	<b>76.32%</b>	0.00%	-13.33%	<b>20.25%</b>	Sucesso

Tabela 4-79: Comparação das avaliações do modelo ME13

Para o Modelo Estratégico 2013 (ME13) podemos verificar que o modelo gerado pela plataforma R (CRAN) utilizando o algoritmo RProp- com entradas normalizadas pela soma absoluta das respostas individuais (/Q) conseguiu incluir 84,21% (32) do total (38) das amostras dentro do erro admissível de 30%,e com um erro médio de 18.65%. Este pode ser considerado um modelo de melhor qualidade que o modelo gerado pela mesma plataforma (R CRAN) com a metodologia de árvores de decisão que obteve 76.32% das amostras dentro do erro admissível e com um erro médio de 20.25%. É importante referir que ambos os modelos conseguiram modelar mais de 55% das amostras dentro de um erro de 20%.

##### 4.6.2 Modelo Estratégico 2014

O Modelo Estratégico 2014 (ME14), é modelado utilizando 70% do conjunto dos dados do ano de 2014 para o conjunto treino. Para o conjunto de avaliação são utilizados os restantes 30% do conjunto dos dados do ano de 2014. E necessário referir que o conjunto de treino e o conjunto de teste são mutuamente exclusivos.



## ESTUDO EMPÍRICO

Modelo	Avaliação		Número de Amostras		% de Amostras		Amplitude (Delta)		Erro	Avaliação Modelo
	Amostras com erro<30%	Amostras com erro<20%	$\epsilon < 30\%$	Total	$\epsilon < 20\%$	$\epsilon < 30\%$	max	min	Médio (%)	
ME14NC	Bom	Bom	61	73	71.23%	83.56%	-10.24%	31.77%	16.85%	Sucesso ®
ME14R (Rprop+)	Ligeiro	Bom	61	73	65.75%	83.56%	-9.76%	7.47%	19.32%	Sucesso
ME14ADR	Ligeiro	Bom	53	73	50.69%	72.60%	14.29%	9.09%	23.30%	Sucesso

*Tabela 4-80: Comparação das avaliações do modelo ME14*

Para o Modelo Estratégico 2014 (ME14) temos o melhor modelo proveniente da plataforma Neural Network Console (Sony) com 83.56% (61) das amostras dentro do limite do erro considerado como admissível. Apesar do modelo gerado pela plataforma R (CRAN) ter obtido o mesmo resultado, o erro médio do modelo ME14NC é de 16.85% e a avaliação gráfica de Bom quer para a função de valores previstos para amostras de erro inferior a 30%, quer para a função de valores previstos para amostras de erro inferior a 20%. Sendo que no modelo ME14R (RProp+) o erro médio foi de 19.32% e avaliação gráfica de Ligeiro para amostras com erro inferior a 30%.

O modelo ME14NC também obteve um número maior de amostras dentro do erro de 20% com 71.23%, enquanto o modelo ME14R (RProp+) obteve 65.75% do número total de amostras, o que intensifica a justificação da escolha.

No entanto é preciso relembrar que modelo ME14NC não foi validado pelo princípio da amplitude, mas uma análise mais detalhada avaliou como desejável o modelo.

Para o modelo gerado com árvore de decisão pela plataforma R (CRAN) o modelo considerou-se como tendo sucesso, mas com resultados aquém dos outros modelos avaliados e referenciados na Tabela 4-80.

### 4.6.3 Modelo Estratégico 2015

O Modelo Estratégico 2015 (ME15), é modelado utilizando 70% do conjunto dos dados do ano de 2015 para o conjunto treino. Para o conjunto de avaliação são utilizados os restantes 30% do conjunto dos dados do ano de 2015. E necessário referir que o conjunto de treino e o conjunto de teste são mutuamente exclusivos.

Modelo	Avaliação		Número de Amostras		% de Amostras		Amplitude (Delta)		Erro	Avaliação Modelo
	Amostras com erro<30%	Amostras com erro<20%	$\epsilon<30\%$	Total	$\epsilon<20\%$	$\epsilon<30\%$	max	min	Médio (%)	
<b>ME15NC</b>	<b>Mau</b>	<b>Ligeiro</b>	<b>36</b>	<b>49</b>	<b>55.10%</b>	<b>73.47%</b>	<b>14.58%</b>	<b>13.78%</b>	<b>19.30%</b>	<b>Insucesso</b>
ME15R (Rprop Avg)	Ligeiro	Médio	37	49	69.39%	75.51%	24.12%	7.14%	16.32%	Sucesso
ME15ADR	Ligeiro	Médio	37	49	55.10%	75.51%	2.78%	15.38%	20.42%	Sucesso

Tabela 4-81: Comparação das avaliações do modelo ME15

Para Modelo Estratégico 2015 a rede neuronal da plataforma Neural Network Console não modelou corretamente. Isto não significa que com outra topologia não pudesse modelar o ambiente de forma aceitável, mas por uma questão de congruência foi utilizada sempre a mesma topologia e os mesmos parâmetros para os modelos gerados através desta plataforma.

O modelo gerado a partir da metodologia de redes neurais da plataforma r (CRAN), nomeadamente ME15R (RProp Avg) foi considerado um pouco melhor que o modelo gerado por árvores de decisão. Sendo que para a RNAs da plataforma R (CRAN) obteve um erro médio de 16.32% e 69.39% das amostras dentro de um erro inferior a 20%. O modelo ME15ADR obteve 75.51% das amostras com um erro inferior ao admissível (30%), mas um erro médio de 20.43% e apenas 55.10% das amostras dentro de um erro de 20%.

#### 4.6.4 Modelo Estratégico 2013 – Conjunto Teste 2014

O Modelo Estratégico 2013 – Conjunto Teste 2014 (ME13T14), é modelado utilizando a totalidade dos dados do ano de 2013 para o conjunto treino. Para o conjunto de avaliação são utilizados os dados do ano de 2014.

Modelo	Avaliação		Número de Amostras		% de Amostras		Amplitude (Delta)		Erro	Avaliação Modelo
	Amostras com erro<30%	Amostras com erro<20%	$\epsilon<30\%$	Total	$\epsilon<20\%$	$\epsilon<30\%$	max	min	Médio (%)	
ME13T14NC	Ligeiro	Médio	140	178	62.92%	78.65%	9.81%	15.68%	19.78%	Sucesso
ME13T14R (Rprop+/Q)	Ligeiro	Bom	142	178	63.48%	79.78%	1.69%	8.24%	20.39%	Sucesso
ME13T14ADR	Médio	Médio	134	178	60.67%	75.28%	2.56%	10.00%	21.99%	Sucesso

Tabela 4-82: Comparação das avaliações do modelo ME13T14

Para as RNAs, o modelo gerado através da plataforma R (CRAN) com o algoritmo RProp+ e a normalização feita com base nas respostas individuais do questionário tiveram uma pequena

margem, na qualidade do modelo, acima da RNA gerada a partir da plataforma Neural Network Console. Enquanto a RNA gerada pela Neural Network Console, com o modelo ME12T14NC, teve um erro médio de 19.78% contra 20.39% obtida pelo modelo ME13T14R (RProp+/Q) gerada pela plataforma R (CRAN). No entanto a RNA do modelo ME13T14R (RProp+/Q) obteve 79.78% das amostras com um erro inferior ao considerado erro admissível, contra 78.65% do modelo ME13T14NC, e ainda conseguiu respeitar melhor o princípio da amplitude com um  $\delta_{\max}$  de 1.69% e um  $\delta_{\min}$  de 8.24%.

O modelo ME13T14ADR, gerado através de árvores de decisão, foi o modelo, dentro dos 3 apresentados, que obteve piores resultados, embora ainda assim aceite como dentro dos parâmetros do desejável.

#### 4.6.5 Modelo Estratégico 2014 – Conjunto Teste 2015

O Modelo Estratégico 2014 – Conjunto Teste 2015 (ME14T15), é modelado utilizando a totalidade dos dados do ano de 2014 para o conjunto treino. Para o conjunto de avaliação são utilizados os dados do ano de 2015.

Modelo	Avaliação		Número de Amostras		% de Amostras		Amplitude (Delta)		Erro	Avaliação Modelo
	Amostras com erro<30%	Amostras com erro<20%	$\epsilon < 30\%$	Total	$\epsilon < 20\%$	$\epsilon < 30\%$	max	min	Médio (%)	
ME14T15NC	Médio	Bom	132	166	69.88%	79.52%	-0.76%	-7.49%	17.90%	Sucesso
ME14T15R (AVG6)	Ligeiro	Bom	134	166	68.07%	80.72%	5.99%	19.28%	18.98%	Sucesso
ME14T15ADR	Médio	Bom	125	166	63.86%	75.30%	-2.63%	-8.33%	20.96%	Sucesso

Tabela 4-83: Comparação das avaliações do modelo ME14T15

O modelo ME14T15ADR, gerado através de árvores de decisão, é notoriamente o pior modelo dos três apresentados na Tabela 4-83, com um erro médio de 20.96% e 75.30% das amostras com um erro inferior ao erro admissível de 30%.

Entre os 2 modelos gerados com RNAs, não existe um modelo que se possa dizer que é o melhor. Enquanto que o modelo ME14T15R (AVG6), consegue incluir 80,72% das amostras no conjunto de amostras com erro inferior a 30% contra 79.52% do modelo ME14T15NC, o modelo ME14T15NC consegue ter um erro médio de 17.90% contra 18.98% do modelo ME14T15R (AVG6).

O que poderia levar ao desempate seria a avaliação gráfica dos 2 modelos com uma pequena diferença de avaliação do comportamento da função de valores previstos (Figura 4.142 e Figura 4.143), onde o modelo ME14T15NC foi avaliado como médio nas amostras com erro inferior a 30%, enquanto o modelo ME14T15R (AVG6) tem uma avaliação como ligeiro.




Figura 4.142: ME14T15NC. Valores e médias por amostra c/erro<30%.




Figura 4.143: ME14T15R (AVG6). Valores e médias por amostra c/erro<30%.

#### 4.6.6 Modelo Estratégico Global

O Modelo Estratégico Global, como referido anteriormente, é criado a partir da totalidade dos dados (após filtro e processamento) referentes aos três anos do estudo. O conjunto treino é composto por 70% do conjunto dos dados totais escolhidos aleatoriamente. O conjunto de avaliação é composto pelos restantes 30% do conjunto dos dados, sendo que frisa-se, mais uma vez, que o conjunto treino e o conjunto de avaliação são mutuamente exclusivos. O sucesso de modelação deste modelo induz a perspetiva que a escolha dos anos para o estudo, considerando o ambiente económico, foi executada de forma correta, uma vez que supostamente existe uma relação entre os dados.

Modelo	Avaliação		Número de Amostras		% de Amostras		Amplitude (Delta)		Erro	Avaliação Modelo
	Amostras com erro<30%	Amostras com erro<20%	$\epsilon < 30\%$	Total	$\epsilon < 20\%$	$\epsilon < 30\%$	max	min	Médio (%)	
MEGlobalR (Rprop Avg)	Ligeiro	Bom	112	142	62.68%	78.87%	4.12%	-5.21%	19.08%	Sucesso
MEGlobalADR	Bom	Bom	100	142	52.82%	70.42%	-2.70%	20.00%	23.17%	Sucesso

Tabela 4-84: Comparação das avaliações do modelo MEGlobal

Mais uma vez, comparando o modelo gerado através de RNAs e o modelo gerado através de árvores de decisão, podemos verificar que a melhor modelação pode ser considerada a gerada através de RNA. Com um erro médio de 19.08% e 78.87% das amostras com um erro inferior ao erro considerado de admissível de 30%. A percentagem de amostras com um erro inferior a 20% situa-se nos 62.68%, cerca de 10% superior ao modelo gerado por ADs. No entanto o modelo gerado por ADs ainda reflete uma qualidade desejável para modelar o ambiente pretendido.

#### 4.6.7 Conclusão do Estudo Comparativo

Numa análise generalizada do estudo comparativo temos os seguintes pontos de interesse:

- ❖ Dos 59 Modelos gerados:
  - 53 modelos gerados com a metodologia RNAs:
    - 48 através da plataforma R (CRAN)
      - 79.17% (38) com Sucesso
        - 54.17% (26) com sucesso nos 5 princípios de avaliação
        - 25.00% (12) com avaliação detalhada do princípio da amplitude
      - 2.08% (1) a falhar no princípio da amplitude
      - 16.67% (8) a falhar no princípio da avaliação gráfica
      - 2.08% (1) a falhar no princípio do erro por conjunto de amostras
    - 5 através da plataforma Neural Network Console (Sony)

- 80% (4) com Sucesso
  - 60% (3) com Sucesso nos 5 princípios de avaliação
  - 20% (1) com avaliação detalhada do princípio da amplitude
- 20% (1) a falhar no princípio da avaliação gráfica
- 6 modelos gerados com a metodologia ADs
  - 100% (6) com sucesso nos 5 princípios de avaliação
    - Princípio do erro por conjunto de amostra com 70.42% a 76.32% das amostras com erro inferior a 30%
    - Princípio do erro médio com 20.25% a 23.30%

Por verificar-se que de uma forma geral as RNAs modelam com mais precisão o ambiente estratégico desejado, mas que nem todos os modelos gerados têm sucesso. A estas RNAs ainda se pode associar uma característica de flexibilidade operacional, alterando a topologia e a parametrização pode-se otimizar as RNAs para obter resultados mais precisos. Um problema mais direto das RNAs é que a criação de um modelo onde as amostras têm uma relação forte não garante que os testes sobre esta tenham sucesso.

Nos modelos gerados pela metodologia das ADs pode verificar-se resultados não tão bons como nas RNAs, mas verifica-se uma consistência maior nos resultados obtidos. A flexibilidade das ADs é baixa o que pode condicionar a categorização das amostras. Enquanto as RNAs são um modelo matemático puro, podendo ser descritas por uma função matemática, as ADs na sua forma de classificadoras comportam-se mais como de modelo de opções e caminhos, onde um conjunto de amostras são classificadas por intervalos caracterizados.

Por último é preciso não esquecer que as ADs providenciam os seus resultados categorizados desta forma a precisão do modelo pode sofrer a consequência da categorização de amostras cujos valores sejam contínuos.

## 5 CONCLUSÃO, LIMITAÇÕES E SUGESTÕES DE TRABALHO FUTURO

### 5.1 Conclusão

O objetivo proposto nesta tese era a verificação da possibilidade de modelar os ambientes estratégicos, através de redes neuronais e/ou árvores de decisão, de forma a que se pudesse rever o impacto nos resultados financeiros, nomeadamente no volume de negócios. Pretendia-se para o sucesso da modelação que se pudesse prever mais de 70%, do conjunto de amostras para teste, com uma precisão de menos de 30% de erro. Por outro lado, pretendia-se um erro médio, do mesmo conjunto amostral, inferior a 25%.

Os dados inerentes ao estudo empírico foram obtidos de duas fontes distintas. As estratégias consideradas no estudo foram obtidas através de um questionário, desenvolvido especificamente para o efeito, feito aos gestores das organizações alvo. Sendo que este questionário envolvia 3 anos (2013 a 2015) e permitia que os gestores avaliassem o nível aplicacional, das estratégias consideradas, nas organizações. O segundo conjunto de dados, referente aos dados financeiros foram retirados de uma base de dados que contém os resultados financeiros declarados pelas organizações.

Os modelos desenvolvidos tinham como entradas o nível aplicacional das estratégias e como saída a variação do volume de negócios de um ano para o outro. Foram feitas um vasto conjunto de experiências que permitiram uma conclusão fidedigna.

Para as redes neuronais considerou-se um total de 53 modelos/algoritmos. Conseguiu-se obter sucesso em 38 (79.17%) dos modelos. Sendo que 1 (2.08%) modelo falhou no princípio da amplitude, ou seja, o ambiente modelado não tinha a amplitude desejada para ser considerado sucesso. Dos 53 modelos, 8 (16.67%) falharam devido ao insucesso da avaliação gráfica, ou seja, o comportamento da função dos dados previstos não era o desejado, que seria um comportamento semelhante ao comportamento da função dos dados reais. Por último, existiu 1 (2.08%) modelo que falhou no princípio do erro por conjunto de amostras, ou seja, o erro médio da previsão ultrapassava o máximo de 25% definido como de aceitável.

Deve-se notar que para todos os modelos existiram mais algoritmos que conseguiram modelar com sucesso do que o contrário. A análise aos resultados verificou que provavelmente o insucesso de modelação protagonizado pelo princípio da avaliação gráfica, ou seja, a avaliação visual do

comportamento da função dos valores previstos, possa em grande parte ser devido ao pequeno número das amostras em relação ao algoritmo utilizado.

Para o modelo que falhou o princípio do erro por conjunto de amostras, ou seja, o erro médio das previsões, este teve um erro de 25,82%, muito perto do erro médio permitido fixado nos 25%. Sendo o modelo em questão referenciado como MEGlobalR e o algoritmo de treino o Rprop+/Q. Este modelo engloba o conjunto de amostras inerentes aos 3 anos incluído no estudo pelo que possa existir alguma discrepância, ainda que pequena, no ambiente económico relativamente a cada um dos anos que leve a uma dificuldade na modelação.

Para as árvores de decisão considerou-se 6 modelos, 1 modelo para cada conjunto de amostras utilizado. O algoritmo utilizado para calculo e obtenção dos modelos foi o RPART incluído na biblioteca rpart da plataforma R (CRAN), que utiliza dados categorizados. Esta modelação tem como objetivo principal a possibilidade de comparação de performance entre as duas modelações apresentadas no estudo.

O desempenho obtido para a modelação através das árvores de decisão foi, para todos os modelos, conseguido com sucesso. O comportamento da função de previsão para amostras com erro inferior a 30% obteve apenas 33.3% de modelos avaliado como ligeiro. Para os outros 66.6% teve uma avaliação de médio (50%) e bom (16.6%). Este nível de avaliação é indicativo da possibilidade de uma modelação com precisão desejada. Para cimentar a possibilidade de uma boa modelação temos ainda os resultados do comportamento da função de precisão para amostras com erro inferior a 20% que apenas tiveram avaliação de médio (33.3%) e bom (66.6%).

Em relação aos erros médios do conjunto de amostras para teste obteve-se entre 50,69% e 63,86% das amostras considerando um erro inferior a 20%, e entre 70,42% e 76,32% considerando um erro máximo de 30%. O erro médio das previsões para cada um dos modelos situou-se entre 20,25% e 23,30%, abaixo do erro admissível máximo proposto de 25%.

Desta forma pode-se concluir que os modelos gerados a partir a metodologia de árvores de decisão têm características previsionais quando induzidos através dos dados utilizados.

No estudo comparativo entre as metodologias para gerar dos modelos (RNAs e ADs) verifica-se que as RNA tendem a modelar o ambiente estratégico com mais precisão, mas que nem sempre a geração do modelo é feita com sucesso. Existe também uma flexibilidade operacional maior com



as RNAs uma vez que permitem a alteração da topologia e dos parâmetros de forma a otimizar a RNA e, por conseguinte, os resultados.

No entanto a metodologia onde são utilizadas ADs, para geração dos modelos, demonstrou uma maior consistência entre os resultados obtidos. É crucial referir que os resultados providenciados pelos modelos gerados com ADs podem ter sofrido uma perda de precisão devido à categorização das amostras.

De forma geral pode-se concluir que através das metodologias de RNAs e ADs, pode-se obter resultados previsionais, com algum grau de precisão, utilizando uma avaliação da aplicação das estratégias em pequenas empresas. O que significa que de uma forma geral a aplicação as estratégias, consoante o nível aplicacional, podem ter um impacto calculado nos resultados financeiros. Os resultados obtidos vão de encontro ao que se pretendia demonstrar nas hipóteses apresentadas nesta tese.

### 5.2 Limitações

Os modelos calculados servem para o ano para o qual os modelos foram construídos. Existem variáveis extrínsecas à aplicação de estratégias que podem ter impacto significativo nos resultados da implementação das mesmas. Por exemplo, num ambiente de crescimento económico é esperado um impacto diferente do que de um ambiente de recessão económica, por isso a modelização tem de estar de acordo com o ambiente económico onde as organizações têm a sua atividade.

Outra limitação está associada às redes neuronais. A modelação através das redes neuronais apenas permite que os resultados admissíveis a serem modelados se situem no intervalo a que pertencem os dados do conjunto treino, desta forma quanto mais afastados forem os dados que se pretendem testar, dos dados de treino, maior será a taxa de erro. Para os modelos gerados com árvores de decisão este problema ainda tem maior impacto, uma vez que a modelização através de árvores de decisão só modela os resultados conhecidos e por isso não categoriza amostras que não existam no conjunto treino, ou seja o intervalo é limitado ao conjunto que serviu para produzir a respetiva árvore de decisão.

O facto de as estratégias utilizadas no estudo serem genéricas não infere um conhecimento do processo de implementação, ou seja, dos recursos despendidos para a implementação da mesma. Logo não é possível saber com exatidão o retorno da implementação de tal estratégia.

### 5.3 Sugestões de Trabalho Futuro

As sugestões inerentes ao estudo que podem ser feitas são variadas. Seria interessante continuar o estudo colocando algumas variáveis relativas ao ambiente económico de forma a alargar o âmbito da modelação. Desta forma poder-se-ia generalizar os modelos para outras economias ou para uma única economia num período de tempo mais alargado.

Outra possibilidade para dar continuação ao estudo seria restringir a atividade das organizações alvo do estudo e utilizar estratégias mais específicas. Desta forma ter-se-ia uma noção mais exata do impacto providenciado pela implementação de certas estratégias, isto porque as estratégias aplicadas podem ter impacto diferente consoante a atividade das organizações.



## REFERÊNCIAS BIBLIOGRÁFICAS

- [1] M. Porter, “What is strategy?,” *Harvard Business Review*, nº Product Number 4134, 1996.
- [2] J. B. Barney e W. S. Hesterly, *Strategic Management and Competitive Advantage - Concepts*, 4th ed., New Delhi: Pearson Prentice Hall, 2012.
- [3] J. D. Curuksu, *Data Driven: An Introduction to Management Consulting in the 21st Century*, New York: Springer, 2018.
- [4] B. Render, R. M. Stair, M. E. Hanna e T. S. Hale, *Quantitative Analysis for Management*, 13th ed., Pearson, 2018.
- [5] E. J. Blocher, D. E. Stout, P. E. Juras e G. Cokins, *Cost Management: A Strategic Emphasis*, 7th ed., New York: Mc Graw Hill, 2016.
- [6] A. Freire, *Estratégia: Sucesso em Portugal*, 12th ed., Lisboa: Editorial Verbo, 2008.
- [7] R. Cordeiro, *Estratégia: O Processo Raciocínio Estratégico em Portugal*, Torres Novas: DPI, 2004.
- [8] M. Hitt, R. D. Ireland e R. Hoskisson, *Concepts Strategic Management: Competitiveness & Globalization*, Canada: Cengage South-Western, 2011.
- [9] G. Jones e C. Hill, *Theory of Strategic Management*, 9th ed., South-Western: Cengage Learning, 2010.
- [10] M. S. Pereira, “A relevância da gestão de talentos e o seu impacto incremental na estratégia organizacional: um estudo qualitativo,” *Media & Jornalismo: Comunicação Estratégica Institucional e Organizacional*, vol. 18, nº 33, pp. 219-234, 2018.
- [11] E. W. Mainardes, J. J. Ferreira e M. L. Raposo, “STRATEGY AND STRATEGIC MANAGEMENT CONCEPTS: ARE THEY RECOGNISED BY MANAGEMENT STUDENTS?,” *E a M: Ekonomie a Management*, vol. XVII, nº 1, pp. 43-61, 2014.
- [12] R. L. d. Costa, N. António, I. Miguel e F. Martinho, “The Analysis of the Four Paradigms of Business Management consulting in Portugal in the Light of the Research Field of Strategy-as-practice,” *Advances in Management & Applied Economics*, vol. 4, nº 3, pp. 39-54, 2014.
- [13] A. d. S. Oliveira, *Master Thesis: Internationalization Strategies for Tourism in Portugal*, Porto: Escola Superior de Tecnologia e Gestão - Politécnico do Porto, 2018.

## REFERÊNCIAS BIBLIOGRÁFICAS

- [14] H. MINTZBERG, B. AHLSTRAND e J. LAMPEL, *Strategy Safari*, New York: The Free Press, 1998.
- [15] D. POWER, M. GANNON, M. MCGINNIS e D. SCHWEIGER, *Strategic Management Skills*, Reading: Addison-Wesley, 1986.
- [16] A. Santos, *Gestão Estratégica: Conceitos, modelos e instrumentos*, Lisboa: Escolar Editora, 2008.
- [17] T. Wheelen e J. D. Hunger, *Strategic Management and Business Policy*, 8th ed., New Jersey: Prentice Hall, 2002.
- [18] J. BARNEY e W. HESTERLY, *Administração Estratégica e Vantagem Competitiva*, São Paulo: Pearson Pentrice Hall, 2007.
- [19] R. KREITNER, *Management*, 6th ed., Boston: Houghton Mifflin Company, 1995.
- [20] G. SALONER, A. SHEPARD e J. PODOLNY, *Strategic Management*, John Wiley & Sons, 2001.
- [21] A. L. C. R. RAPOSO, *Estratégia de comunicação como um processo de tomada de decisão: uma nova abordagem na compreensão da formulação estratégica em Relações Públicas*, Lisboa: ISCTE-IUL, 2014.
- [22] R. Comerford e D. Callaghan, *Strategic Management: Text, Tools, and Cases for Business Policy*, Boston: Kent Publishing Company, 1985.
- [23] J. Andrez e M. Cruz, *Decisão de Investir em Ambiente de Incerteza e Risco*, Coimbra: Actual Editora, 2013.
- [24] E. d. C. Sequeira, “Os Indicadores de Confiança, o Sentimento do Investidor e o Mercado de Capitais Português,” UTL/ISEG, Lisboa, 2011.
- [25] J. C. Fuhrer, “What Role Does Consumer Sentiment Play in the U.S. Macroeconomy?,” *New England Economic*, pp. 32-44, 1993.
- [26] D. S. Pinho, “Confiança do consumidor e actividade económica: Evidência Europeia,” Universidade de Aveiro, Aveiro, 2014.
- [27] M. Tkác e R. Verner, “Artificial neural networks in business: Two decades of research,” *Applied Soft Computing*, vol. 38, pp. 788-804, 2016.
- [28] L. Kryzanowski e M. Galler, “Analysis of Small-Business Financial Statements Using Neural Nets,” *Journal of Accounting, Auditing & Finance*, vol. 10, nº 1, pp. 147-170, 1995.

- [29] A. Sharma e A. Chopra, “Artificial Neural Networks: Applications In Management,” *IOSR Journal of Business and Management*, vol. 12, nº 5, pp. 32-40, 2013.
- [30] B. Green e J. Choi, “Assessing the risk of management fraud through neural network technology,” *Audit. J. Pract. Theory*, vol. 16, pp. 14-28, 1997.
- [31] H. Chen, S. Huang e C. Kuo, “Using the artificial neural network to predict fraud litigation: some empirical evidence from emerging markets,” *Expert Systems with Applications*, vol. 36, nº 2, pp. 1478-1484, 2009.
- [32] J. Z. Lei e A. A. Ghorbani, “Improved competitive learning neural networks for network intrusion and fraud detection,” *Neurocomputing*, vol. 75, nº 1, pp. 135-145, 2012.
- [33] P. A. Estévez, C. M. Held e C. A. Perez, “Subscription fraud prevention in telecommunications using fuzzy rules and neural networks,” *Expert Systems with Applications*, vol. 31, nº 2, pp. 337-344, 2006.
- [34] S. Thomassey e M. Happiette, “A neural clustering and classification system for sales forecasting of new apparel items,” *Applied Soft Computing*, vol. 7, nº 4, pp. 1177-1187, 2007.
- [35] A. P. Ansuji, M. E. Camargo, R. Radharamanan e D. G. Petry, “Sales forecasting using time series and neural networks,” *Computers & Industrial Engineering*, vol. 31, nº 1-2, pp. 421-424, 1996.
- [36] I. Alon, M. Qi e R. J. Sadowski, “Forecasting aggregate retail sales:: a comparison of artificial neural networks and traditional methods,” *Journal of Retailing and Consumer Services*, vol. 8, nº 3, pp. 147-156, 2001.
- [37] R. J. Kuo e K. C. Xue, “A decision support system for sales forecasting through fuzzy neural networks with asymmetric fuzzy weights,” *Decision Support Systems*, vol. 24, nº 2, pp. 105-126, 1998.
- [38] R. J. Kuo, P. Wu e C. .. Wang, “An intelligent sales forecasting system through integration of artificial neural networks and fuzzy neural networks with fuzzy weight elimination,” *Neural Networks*, vol. 15, nº 7, pp. 909-925, 2002.
- [39] R. M. Grant, “Strategic planning in a turbulent environment: evidence from the oil majors,” *Strategic Management Journal*, vol. 24, nº 6, pp. 491-517, 2003.
- [40] Y. Shachmurove, “Applying Artificial Neural Networks to Business, Economics and Finance,” 2002.
- [41] G. Guido, M. I. Prete, S. Miraglia e I. D. Marec, “Targeting direct marketing campaigns by neural networks,” *Journal of Marketing Management*, vol. 27, nº 9-10, pp. 992-1006, 2011.

- [42] N. Mahbub, S. K. Paul e A. Azeem, “A neural approach to product demand forecasting,” *International Journal of Industrial and Systems Engineering*, vol. 15, nº 1, pp. 1-18, 2013.
- [43] O. I. Abiodun, A. Jantan, A. E. Omolara, K. V. Dada, N. A. Mohamed e H. Arshad, “State-of-the-art in artificial neural network applications: A survey,” *Heliyon*, vol. 4, nº 11, 2018.
- [44] T. J. Bihl, W. A. Young e G. R. Weckman, “Artificial Neural Networks for Business Analytics,” em *Encyclopedia of Business Analytics and Optimization*, Hershey, IGI Global, 2014.
- [45] M. Kraus, S. Feuerriegel e A. Oztekinb, “Deep learning in business analytics and operations research: Models, applications and managerial implications,” *European Journal of Operational Research*, vol. 281, nº 3, pp. 628-641, 2020.
- [46] D. Alaminos, S. M. Fernández, P. M. Neves e J. A. C. Santos, “Predicting Sovereign Debt Crises with Fuzzy Decision Trees,” *Journal of Scientific & Industrial Research*, vol. 78, pp. 733-737, 2019.
- [47] Y. Ikeda, O. Kubo e Y. Kobayashi, “Forecast of business performance using an,” *Physica A*, vol. 344, pp. 87-94, 2004.
- [48] S. Höppner, E. Stripling, B. Baesens, S. v. Broucke e T. Verdonck, “Profit driven decision trees for churn prediction,” *European Journal of Operational Research*, 2018.
- [49] J. Brédy, J. Gallichand, P. Celicourt e S. J. Gumiere, “Water table depth forecasting in cranberry fields using two decision-treemodeling,” *Agricultural Water Management*, vol. 233, 2020.
- [50] J.-H. Chen, H.-H. Wei, C.-L. Chen, H.-Y. Wei, Y.-P. Chen e Z. Ye, “A practical approach to determining critical macroeconomic factors in air-traffic volume based on K-means clustering and decision-tree classification,” *Journal of Air Transport Management*, vol. 82, 2020.
- [51] H. Wang e M. Hong, “Online ad effectiveness evaluation with a two-stage method using a Gaussian filter and decision tree approach,” *Electronic Commerce Research and Applications*, vol. 35, 2019.
- [52] H. Wang e M. Hong, “A 2020 perspective on “Online ad effectiveness evaluation with a two-stage method using a Gaussian filter and decision tree approach”,” *Electronic Commerce Research and Applications*, 2020.
- [53] F. Zhou, Q. Zhang, D. Sornette e L. Jiang, “Cascading logistic regression onto gradient boosted decision trees for forecasting and trading stock indices,” *Applied Soft Computing Journal*, vol. 84, 2019.

- [54] P. Osipovs, “Classification tree applying for automated CV filtering in transport company,” em *ICTE in Transportation and Logistics 2018*, Riga, 2018.
- [55] R. M. Aguilar-Chinea, I. C. Rodriguez, C. Expósito, B. Melian-Batista e J. M. Moreno-Vega, “Using a decision tree algorithm to predict the robustness of a transshipment schedule,” em *ICTE in Transportation and Logistics 2018*, Riga, 2018.
- [56] N. Gupta, R. Hauser e N. Johnson, “Using Artificial Market Models to Forecast Financial Time-Series,” Oxford University Computing Laboratory, Oxford, 2005.
- [57] J. Barunik, T. Aste, T. D. Matteo e R. Liu, “Understanding the source of multifractality in financial markets,” *Physica A: Statistical Mechanics and its Applications*, vol. 391, nº 17, pp. 4234-4251, 2012.
- [58] D. F. Hendrya e G. E. Mizon, “Unpredictability in economic analysis, econometric modeling and forecasting,” *Journal of Econometrics*, vol. 182, nº 1, pp. 186-195, 2014.
- [59] P. K. Pandey, V. Pandey, R. Singh e S. R. Bhakar, “Stochastic Modelling of Actual Black Gram Evapotranspiration,” *Journal of Water Resource and Protection*, vol. 1, nº 6, pp. 448-455, 2009.
- [60] K. Kočišováa e M. Mišanková, “Discriminant analysis as a tool for forecasting company’s financial health,” em *Contemporary Issues in Business, Management and Education 2013*, 2014.
- [61] H. Mo e J. Wang, “Return scaling cross-correlation forecasting by stochastic time strength neural network in financial market dynamics,” *Soft Computing*, vol. 22, nº 9, p. 3097–3109, 2018.
- [62] M. Mihalovic, “Financial ratios as a tool for financial distress detection,” em *Conference: EDAMBA 2015 " The Era of Science Diplomacy: Implications for Economics, Business, Management and Related Disciplines"*, 2015.
- [63] W.-Q. Duan e H. E. Stanley, “Cross-correlation and the predictability of financial return series,” *Physica A*, vol. 390, nº 2, pp. 290-296, 2011.
- [64] A. K. Rout, P. Dash, R. Dash e R. Bisoi, “Forecasting financial time series using a low complexity recurrent neural network and evolutionary learning approach,” *Journal of King Saud University - Computer and Information Sciences*, vol. 29, nº 4, pp. 536-552, 2017.
- [65] H. Mo, J. Wang e H. Niu, “Exponent back propagation neural network forecasting for financial cross-correlation relationship,” *Expert Systems with Applications*, vol. 53, nº 1, pp. 106-116, 2016.



- [66] S. Nayak, B. Misra e H. Behera, “Artificial chemical reaction optimization of neural networks for efficient prediction of stock market indices,” *Ain Shams Engineering Journal*, vol. 8, nº 3, pp. 371-390, 2017.
- [67] J. Schmidhuber, “EVOLINO,” [Online]. Available: <http://people.idsia.ch/~juergen/evolino.html>. [Acedido em 28 1 2019].
- [68] N. Maknickienė, “Selection of orthogonal investment portfolio using Evolino RNN trading model,” em *Contemporary Issues in Business, Management and Education 2013*, 2013.
- [69] A. Bagheri, H. M. Peyhani e M. Akbari, “Financial forecasting using ANFIS networks with Quantum-behaved Particle Swarm Optimization,” *Expert Systems with Applications*, vol. 41, nº 14, pp. 6235-6250, 2014.
- [70] S. Mammadli, “Financial time series prediction using artificial neural network based on Levenberg-Marquardt algorithm,” em *9th International Conference on Theory and Application of Soft Computing, Computing with Words and Perception*, Budapest, Hungary, 2017.
- [71] C. Lazăr e M. Lazăr, “Using the Method of Decision Trees in the Forecasting Activity,” *Economic Insights – Trends and Challenges*, vol. 6, pp. 41-48, 2015.
- [72] E. Tsang, P. Yung e J. Li, “EDDIE-Automation, a decision support tool for financial forecasting,” *Decision Support Systems*, vol. 37, nº 4, pp. 559-565, 2004.
- [73] J. Jeganathan, G. Kaur e S. Joseph, “FINANCIAL FORECASTING USING DECISION TREE (REPTree & C4.5) AND NEURAL NETWORKS (K\*) FOR HANDLING THE MISSING VALUES,” *ICTACT JOURNAL ON SOFT COMPUTING*, vol. 7, nº 3, pp. 1473-1477, 2017.
- [74] F. Shi e C. Ghedira, “Intention-Based Online Consumer Classification for Recommendation and Personalization,” em *Fourth IEEE Workshop on Hot Topics in Web Systems and Technologies*, Washington DC, 2016.
- [75] I. D. Mienye, Y. Sun e Z. Wang, “Prediction performance of improved decision tree-based algorithms: A review,” em *2nd International Conference on Sustainable Materials Processing and Manufacturing*, Sun City, 2019.
- [76] R. Kumar, “Decision Tree for the Weather Forecasting,” *International Journal of Computer Applications*, vol. 76, nº 2, pp. 31-34, 2013.
- [77] J. Marques, *Reconhecimentos de Padrões: Métodos Estatísticos e Neurais*, Lisbon: IST Press, 1999.

- [78] M. Kubat, *An Introduction to Machine Learning*, 2nd ed., Miami: Springer, 2017.
- [79] T. M. Mitchell, *Machine Learning*, McGraw-Hill, 1997.
- [80] L. Chong, M. Abbas, A. M. Flintsch e B. Higgs, “A rule-based neural network approach to model driver naturalistic behavior in traffic,” *Transportation Research Part C: Emerging Technologies*, pp. 207-223, 2012.
- [81] L. Badea, “Predicting Consumer Behavior with Artificial Neural Networks,” *Procedia Economics and Finance*, vol. 15, pp. 238-246, 2014.
- [82] M. A. Riedmiller, “Advanced supervised learning in multi-layer perceptrons — From backpropagation to adaptive learning algorithms,” *Computer Standards & Interfaces*, vol. 16, nº 3, pp. 265-278, 1994.
- [83] C. Igel e M. Husken, “Improving the Rprop Learning Algorithm,” em *Proceedings of the Second International Symposium on Neural Computation NC2000*, 2000.
- [84] A. D. Anastasiadis, G. D. Magoulas e M. N. Vrahatis, “New globally convergent training scheme based on the resilient propagation algorithm,” *Neurocomputing*, vol. 64, p. 253–270, 2005.
- [85] T. M. Bailey, “Convergence of Rprop and variants,” *Neurocomputing*, vol. 159, nº 2, pp. 90-95, 2015.

## Índice de Anexos

Lista de Figuras (Anexos).....	3
Lista de Tabelas (Anexos) .....	11
A ANEXOS .....	15
A.1 Questionário .....	15
A.1.1 Formulação .....	15
A.1.2 Dados .....	20
A.2 Dados Económicos.....	21
A.3 Resultados Experimentais .....	41
A.3.1 Redes Neurais (Net Console).....	41
A.3.2 Redes Neurais R.....	47
A.3.3 Árvores de Decisão R .....	69
A.4 Gráficos e Tabelas.....	101
A.4.1 Redes Neurais .....	101
A.4.2 Avaliação Global RNAs .....	179
A.4.3 Árvores de Decisão .....	181
A.4.4 Avaliação Global ADs .....	191
A.5 Árvores de Decisão .....	192
A.5.1 R (CRAN) .....	192
A.6 Desenvolvimento de Software (Automatização).....	198
A.6.1 Redes Neurais .....	198
A.6.2 Árvores de Decisão .....	211



## Lista de Figuras (Anexos)

FIGURA A.1: ME13NC. VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	101
FIGURA A.2: ME13NC. VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	101
FIGURA A.3: ME13NC. VALORES POR AMOSTRA C/ERRO>30%.	101
FIGURA A.4 : ME13NC. MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	101
FIGURA A.5: ME2013NC. NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO.	101
FIGURA A.6: ME14NC. VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	102
FIGURA A.7: ME14NC. VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	102
FIGURA A.8: ME14NC. VALORES POR AMOSTRA C/ERRO>30%.	102
FIGURA A.9: ME14NC. MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	102
FIGURA A.10: ME14NC. NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO.	102
FIGURA A.11: : ME15NC. VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	103
FIGURA A.12: ME15NC. VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	103
FIGURA A.13: ME15NC. VALORES POR AMOSTRA C/ERRO>30%.	103
FIGURA A.14: ME15NC. MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	103
FIGURA A.15: ME15NC. NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO.	103
FIGURA A.16: ME13T14NC. VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	104
FIGURA A.17: ME13T14NC. VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	104
FIGURA A.18: ME13T14NC. VALORES POR AMOSTRA C/ERRO>30%.	104
FIGURA A.19: ME13T14NC. MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	104
FIGURA A.20: ME13T14NC. NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO.	105
FIGURA A.21: ME14T15NC. VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	105
FIGURA A.22: ME14T15NC. VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	105
FIGURA A.23: ME14T15NC. VALORES POR AMOSTRA C/ERRO>30%.	105
FIGURA A.24: ME14T15NC. MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	106
FIGURA A.25: ME14T15NC. NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO.	106
FIGURA A.26: ME13R (RPROP-). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	106
FIGURA A.27: ME13R(RPROP-). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	106
FIGURA A.28: ME13R (RPROP-). VALORES POR AMOSTRA C/ERRO>30%.	107
FIGURA A.29: ME13R (RPROP-). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	107
FIGURA A.30: ME13R (RPROP-). MODELAÇÃO DO CONJ. DE TREINO.	107
FIGURA A.31: ME13R (RPROP-). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	107
FIGURA A.32: ME13R (RPROP-). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO.	107
FIGURA A.33: ME13R (RPROP+). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	108
FIGURA A.34: ME13R(RPROP+). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	108
FIGURA A.35: ME13R (RPROP+). VALORES POR AMOSTRA C/ERRO>30%.	108
FIGURA A.36: ME13R (RPROP+). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	108
FIGURA A.37: ME13R (RPROP+). MODELAÇÃO DO CONJ. DE TREINO	108
FIGURA A.38: ME13R (RPROP+). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	109
FIGURA A.39: ME13R (RPROP+). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO.	109
FIGURA A.40: ME13R (SAG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	109
FIGURA A.41: ME13R (SAG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	109
FIGURA A.42: ME13R (SAG). VALORES POR AMOSTRA C/ERRO>30%.	109
FIGURA A.43: ME13R (SAG). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	110
FIGURA A.44: ME13R (SAG). MODELAÇÃO DO CONJ. DE TREINO	110
FIGURA A.45: ME13R (SAG). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	110
FIGURA A.46: ME13R (SAG). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO.	110
FIGURA A.47: ME13R (AVG RPROP). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	111
FIGURA A.48: ME13R (RPROP AVG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	111
FIGURA A.49: ME13R (RPROP AVG). VALORES POR AMOSTRA C/ERRO>30%.	111
FIGURA A.50: ME13R (RPROP AVG). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO.	111

FIGURA A.51: ME13R (RPROP AVG). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	111
FIGURA A.52: ME13R (RPROP AVG). MODELAÇÃO DO CONJ. DE TREINO	112
FIGURA A.53: ME13R (RPROP AVG). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	112
FIGURA A.54: ME13R (AVG6). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	112
FIGURA A.55: ME13R (AVG6). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	112
FIGURA A.56: ME13R (AVG6). VALORES POR AMOSTRA C/ERRO>30%.	113
FIGURA A.57: ME13R (AVG6). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	113
FIGURA A.58: ME13R (AVG6). MODELAÇÃO DO CONJ. DE TREINO	113
FIGURA A.59: ME13R (AVG6). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	113
FIGURA A.60: ME13R (AVG6). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO.	113
FIGURA A.61: ME13R (RPROP-/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	114
FIGURA A.62: ME13R (RPROP-/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	114
FIGURA A.63: ME13R (RPROP-/Q). VALORES POR AMOSTRA C/ERRO>30%.	114
FIGURA A.64: ME13R (RPROP-/Q). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	114
FIGURA A.65: ME13R (RPROP-/Q). MODELAÇÃO DO CONJ. DE TREINO	114
FIGURA A.66: ME13R (RPROP-/Q). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	115
FIGURA A.67: ME13R (RPROP-/Q). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO.	115
FIGURA A.68: ME13R (RPROP+/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	115
FIGURA A.69: ME13R (RPROP+/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	115
FIGURA A.70: ME13R (RPROP+/Q). VALORES POR AMOSTRA C/ERRO>30%.	116
FIGURA A.71: ME13R (RPROP+/Q). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	116
FIGURA A.72: ME13R (RPROP+/Q). MODELAÇÃO DO CONJ. DE TREINO	116
FIGURA A.73: ME13R (RPROP+/Q). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	116
FIGURA A.74: ME13R (RPROP+/Q). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO.	116
FIGURA A.75: ME13R (SAG/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	117
FIGURA A.76: ME13R (SAG/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	117
FIGURA A.77: ME13R (SAG/Q). VALORES POR AMOSTRA C/ERRO>30%.	117
FIGURA A.78: ME13R (SAG/Q). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	117
FIGURA A.79: ME13R (SAG/Q). MODELAÇÃO DO CONJ. DE TREINO	117
FIGURA A.80: ME13R (SAG/Q). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	118
FIGURA A.81: ME13R (SAG/Q). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO.	118
FIGURA A.82: ME14R (RPROP-). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	118
FIGURA A.83: ME14R (RPROP-). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	118
FIGURA A.84: ME14R (RPROP-). VALORES POR AMOSTRA C/ERRO>30%.	119
FIGURA A.85: ME14R (RPROP-). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	119
FIGURA A.86: ME14R (RPROP-). MODELAÇÃO DO CONJ. DE TREINO	119
FIGURA A.87: ME14R (RPROP-). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	119
FIGURA A.88: ME14R (RPROP-). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO.	119
FIGURA A.89: ME14R (RPROP+). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	120
FIGURA A.90: ME14R (RPROP+). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	120
FIGURA A.91: ME14R (RPROP+). VALORES POR AMOSTRA C/ERRO>30%.	120
FIGURA A.92: ME14R (RPROP+). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	120
FIGURA A.93: ME14R (RPROP+). MODELAÇÃO DO CONJ. DE TREINO	120
FIGURA A.94: ME14R (RPROP+). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	121
FIGURA A.95: ME14R (RPROP+). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	121
FIGURA A.96: ME14R (SAG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	121
FIGURA A.97: ME14R (SAG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	121
FIGURA A.98: ME14R (SAG). VALORES POR AMOSTRA C/ERRO>30%.	122
FIGURA A.99: ME14R (SAG). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	122
FIGURA A.100: ME14R (SAG). MODELAÇÃO DO CONJ. DE TREINO	122
FIGURA A.101: ME14R (SAG). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	122
FIGURA A.102: ME14R (SAG). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	122

FIGURA A.103: ME14R (AVG RPROP). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	123
FIGURA A.104: ME14R (RPROP AVG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	123
FIGURA A.105: ME14R (SAG). VALORES POR AMOSTRA C/ERRO>30%.	123
FIGURA A.106: ME14R (RPROP AVG). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	123
FIGURA A.107: ME14R (RPROP AVG). MODELAÇÃO DO CONJ. DE TREINO	123
FIGURA A.108: ME14R (RPROP AVG). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	124
FIGURA A.109: ME14R (RPROP AVG). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	124
FIGURA A.110: ME14R (AVG6). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	124
FIGURA A.111: ME14R (AVG6). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	124
FIGURA A.112: ME14R (AVG6). VALORES POR AMOSTRA C/ERRO>30%.	125
FIGURA A.113: ME14R (AVG6). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	125
FIGURA A.114: ME14R (AVG6). MODELAÇÃO DO CONJ. DE TREINO	125
FIGURA A.115: ME14R (AVG6). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	125
FIGURA A.116: ME14R (AVG6). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	125
FIGURA A.117: ME14R (RPROP-/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	126
FIGURA A.118: ME14R (RPROP-/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	126
FIGURA A.119: ME14R (RPROP-/Q). VALORES POR AMOSTRA C/ERRO>30%.	126
FIGURA A.120: ME14R (RPROP-/Q). MODELAÇÃO DO CONJ. DE TREINO	126
FIGURA A.121: ME14R (RPROP-/Q). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	126
FIGURA A.122: ME14R (RPROP-/Q). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	127
FIGURA A.123: ME14R (RPROP-/Q). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	127
FIGURA A.124: ME14R (RPROP+/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	127
FIGURA A.125: ME14R (RPROP+/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	127
FIGURA A.126: ME14R (RPROP+/Q). VALORES POR AMOSTRA C/ERRO>30%.	128
FIGURA A.127: ME14R (RPROP+/Q). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	128
FIGURA A.128: ME14R (RPROP+/Q). MODELAÇÃO DO CONJ. DE TREINO	128
FIGURA A.129: ME14R (RPROP+/Q). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	128
FIGURA A.130: ME14R (RPROP+/Q). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	128
FIGURA A.131: ME14R (SAG/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	129
FIGURA A.132: ME14R (SAG/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	129
FIGURA A.133: ME14R (SAG/Q). VALORES POR AMOSTRA C/ERRO>30%.	129
FIGURA A.134: ME14R (SAG/Q). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	129
FIGURA A.135: ME14R (SAG/Q). MODELAÇÃO DO CONJ. DE TREINO	129
FIGURA A.136: ME14R (SAG/Q). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	130
FIGURA A.137: ME14R (SAG/Q). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	130
FIGURA A.138: ME15R (RPROP-). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	130
FIGURA A.139: ME15R (RPROP-). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	130
FIGURA A.140: ME15R (RPROP-). VALORES POR AMOSTRA C/ERRO>30%.	131
FIGURA A.141: ME15R (RPROP-). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	131
FIGURA A.142: ME15R (RPROP-). MODELAÇÃO DO CONJ. DE TREINO.	131
FIGURA A.143: ME15R (RPROP-). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	131
FIGURA A.144: ME15R (RPROP-). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	131
FIGURA A.145: ME15R (RPROP+). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	132
FIGURA A.146: ME15R (RPROP+). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	132
FIGURA A.147: ME15R (RPROP+). VALORES POR AMOSTRA C/ERRO>30%	132
FIGURA A.148: ME15R (RPROP+). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	132
FIGURA A.149: ME15R (RPROP+). MODELAÇÃO DO CONJ. DE TREINO.	132
FIGURA A.150: ME15R (RPROP+). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	133
FIGURA A.151: ME15R (RPROP+). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	133
FIGURA A.152: ME15R (SAG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	133
FIGURA A.153: ME15R (SAG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	133
FIGURA A.154: ME15R (SAG). VALORES POR AMOSTRA C/ERRO>30%	134

FIGURA A.155: ME15R (SAG). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	134
FIGURA A.156: ME15R (SAG). MODELAÇÃO DO CONJ. DE TREINO.	134
FIGURA A.157: ME15R (SAG). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	134
FIGURA A.158: ME15R (SAG). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	134
FIGURA A.159: ME15R (RPROP AVG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	135
FIGURA A.160: ME15R (RPROP AVG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	135
FIGURA A.161: ME15R (RPROP AVG). VALORES POR AMOSTRA C/ERRO>30%	135
FIGURA A.162: ME15R (RPROP AVG). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	135
FIGURA A.163: ME15R (RPROP AVG). MODELAÇÃO DO CONJ. DE TREINO.	135
FIGURA A.164: ME15R (RPROP AVG). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	136
FIGURA A.165: ME15R (RPROP AVG). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	136
FIGURA A.166: ME15R (AVG6). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	136
FIGURA A.167: ME15R (AVG6). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	136
FIGURA A.168: ME15R (AVG6). VALORES POR AMOSTRA C/ERRO>30%	137
FIGURA A.169: ME15R (AVG6). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	137
FIGURA A.170: ME15R (AVG6). MODELAÇÃO DO CONJ. DE TREINO.	137
FIGURA A.171: ME15R (AVG6). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	137
FIGURA A.172: ME15R (AVG6). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	137
FIGURA A.173: ME15R (RPROP-/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	138
FIGURA A.174: ME15R (RPROP-/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	138
FIGURA A.175: ME15R (RPROP-/Q). VALORES POR AMOSTRA C/ERRO>30%	138
FIGURA A.176: ME15R (RPROP-/Q). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	138
FIGURA A.177: ME15R (RPROP-/Q). MODELAÇÃO DO CONJ. DE TREINO.	138
FIGURA A.178: ME15R (RPROP-/Q). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	139
FIGURA A.179: ME15R (RPROP-/Q). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	139
FIGURA A.180: ME15R (RPROP+/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	139
FIGURA A.181: ME15R (RPROP+/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	139
FIGURA A.182: ME15R (RPROP+/Q). VALORES POR AMOSTRA C/ERRO>30%	140
FIGURA A.183: ME15R (RPROP+/Q). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	140
FIGURA A.184: ME15R (RPROP+/Q). MODELAÇÃO DO CONJ. DE TREINO.	140
FIGURA A.185: ME15R (RPROP+/Q). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	140
FIGURA A.186: ME15R (RPROP+/Q). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	140
FIGURA A.187: ME15R (SAG/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	141
FIGURA A.188: ME15R (SAG/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	141
FIGURA A.189: ME15R (SAG/Q). VALORES POR AMOSTRA C/ERRO>30%	141
FIGURA A.190: ME15R (SAG/Q). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	141
FIGURA A.191: ME15R (SAG/Q). MODELAÇÃO DO CONJ. DE TREINO.	141
FIGURA A.192: ME15R (SAG/Q). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	142
FIGURA A.193: ME15R (SAG/Q). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	142
FIGURA A.194: ME13T14R (RPROP-). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	142
FIGURA A.195: ME13T14R (RPROP-). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	142
FIGURA A.196: ME13T14R (RPROP-). VALORES POR AMOSTRA C/ERRO>30%	143
FIGURA A.197: ME13T14R (RPROP-). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	143
FIGURA A.198: ME13T14R (RPROP-). MODELAÇÃO DO CONJ. DE TREINO.	143
FIGURA A.199: ME13T14R (RPROP-). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	143
FIGURA A.200: ME13T14R (RPROP-). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	143
FIGURA A.201: ME13T14R (RPROP+). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	144
FIGURA A.202: ME13T14R (RPROP+). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	144
FIGURA A.203: ME13T14R (RPROP+). VALORES POR AMOSTRA C/ERRO>30%	144
FIGURA A.204: ME13T14R (RPROP+). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	144
FIGURA A.205: ME13T14R (RPROP+). MODELAÇÃO DO CONJ. DE TREINO.	144
FIGURA A.206: ME13T14R (RPROP+). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	145



FIGURA A.207: ME13T14R (RProp+). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	145
FIGURA A.208: ME13T14R (SAG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	145
FIGURA A.209: ME13T14R (SAG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	145
FIGURA A.210: ME13T14R (SAG). VALORES POR AMOSTRA C/ERRO>30%	146
FIGURA A.211: ME13T14R (SAG). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	146
FIGURA A.212: ME13T14R (SAG). MODELAÇÃO DO CONJ. DE TREINO.	146
FIGURA A.213: ME13T14R (SAG). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	146
FIGURA A.214: ME13T14R (SAG). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	146
FIGURA A.215: ME13T14R (RProp AVG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	147
FIGURA A.216: ME13T14R (RProp AVG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	147
FIGURA A.217: ME13T14R (RProp AVG). VALORES POR AMOSTRA C/ERRO>30%	147
FIGURA A.218: ME13T14R (RProp AVG). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	147
FIGURA A.219: ME13T14R (RProp AVG). MODELAÇÃO DO CONJ. DE TREINO.	147
FIGURA A.220: ME13T14R (RProp AVG). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	148
FIGURA A.221: ME13T14R (RProp AVG). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	148
FIGURA A.222: ME13T14R (AVG6). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	148
FIGURA A.223: ME13T14R (AVG6). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	148
FIGURA A.224: ME13T14R (AVG6). VALORES POR AMOSTRA C/ERRO>30%	149
FIGURA A.225: ME13T14R (AVG6). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	149
FIGURA A.226: ME13T14R (AVG6). MODELAÇÃO DO CONJ. DE TREINO.	149
FIGURA A.227: ME13T14R (AVG6). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	149
FIGURA A.228: ME13T14R (AVG6). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	149
FIGURA A.229: ME13T14R (RProp-/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	150
FIGURA A.230: ME13T14R (RProp-/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	150
FIGURA A.231: ME13T14R (RProp-/Q). VALORES POR AMOSTRA C/ERRO>30%	150
FIGURA A.232: ME13T14R (RProp-/Q). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	150
FIGURA A.233: ME13T14R (RProp-/Q). MODELAÇÃO DO CONJ. DE TREINO.	150
FIGURA A.234: ME13T14R (RProp-/Q). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	151
FIGURA A.235: ME13T14R (RProp-/Q). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	151
FIGURA A.236: ME13T14R (RProp+/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	151
FIGURA A.237: ME13T14R (RProp+/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	151
FIGURA A.238: ME13T14R (RProp+/Q). VALORES POR AMOSTRA C/ERRO>30%	152
FIGURA A.239: ME13T14R (RProp+/Q). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	152
FIGURA A.240: ME13T14R (RProp+/Q). MODELAÇÃO DO CONJ. DE TREINO.	152
FIGURA A.241: ME13T14R (RProp+/Q). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	152
FIGURA A.242: ME13T14R (RProp+/Q). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	152
FIGURA A.243: ME13T14R (SAG/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	153
FIGURA A.244: ME13T14R (SAG/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%:	153
FIGURA A.245: ME13T14R (SAG/Q). VALORES POR AMOSTRA C/ERRO>30	153
FIGURA A.246: ME13T14R (SAG/Q). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	153
FIGURA A.247: ME13T14R (SAG/Q). MODELAÇÃO DO CONJ. DE TREINO.	153
FIGURA A.248: ME13T14R (SAG/Q). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	154
FIGURA A.249: ME13T14R (SAG/Q). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	154
FIGURA A.250: ME14T15R (RProp-). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	154
FIGURA A.251: ME14T15R (RProp-). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	154
FIGURA A.252: ME14T15R (RProp-). VALORES POR AMOSTRA C/ERRO>30%	155
FIGURA A.253: ME14T15R (RProp-). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	155
FIGURA A.254: ME14T15R (RProp-). MODELAÇÃO DO CONJ. DE TREINO.	155
FIGURA A.255: ME14T15R (RProp-). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	155
FIGURA A.256: ME14T15R (RProp-). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	155
FIGURA A.257: ME14T15R (RProp). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	156
FIGURA A.258: ME14T15R (RProp+). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	156

FIGURA A.259: ME14T15R (RPROP+). VALORES POR AMOSTRA C/ERRO>30%	156
FIGURA A.260: ME14T15R (RPROP+). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	156
FIGURA A.261: ME14T15R (RPROP+). MODELAÇÃO DO CONJ. DE TREINO.	156
FIGURA A.262: ME14T15R (RPROP+). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	157
FIGURA A.263: ME14T15R (RPROP+). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	157
FIGURA A.264: ME14T15R (SAG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	157
FIGURA A.265: ME14T15R (SAG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	157
FIGURA A.266: ME14T15R (SAG). VALORES POR AMOSTRA C/ERRO>30%	158
FIGURA A.267: ME14T15R (SAG). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	158
FIGURA A.268: ME14T15R (SAG). MODELAÇÃO DO CONJ. DE TREINO.	158
FIGURA A.269: ME14T15R (SAG). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	158
FIGURA A.270: ME14T15R (SAG). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	158
FIGURA A.271: ME14T15R (RPROP AVG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	159
FIGURA A.272: ME14T15R (RPROP AVG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	159
FIGURA A.273: ME14T15R (RPROP AVG). VALORES POR AMOSTRA C/ERRO>30%	159
FIGURA A.274: ME14T15R (RPROP AVG). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	159
FIGURA A.275: ME14T15R (RPROP AVG). MODELAÇÃO DO CONJ. DE TREINO.	159
FIGURA A.276: ME14T15R (RPROP AVG). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	160
FIGURA A.277: ME14T15R (RPROP AVG). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	160
FIGURA A.278: ME14T15R (AVG6). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	160
FIGURA A.279: ME14T15R (AVG6). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	160
FIGURA A.280: ME14T15R (AVG6). VALORES POR AMOSTRA C/ERRO>30%	161
FIGURA A.281: ME14T15R (AVG6). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	161
FIGURA A.282: ME14T15R (AVG6). MODELAÇÃO DO CONJ. DE TREINO.	161
FIGURA A.283: ME14T15R (AVG6). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	161
FIGURA A.284: ME14T15R (AVG6). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	161
FIGURA A.285: ME14T15R (RPROP-/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	162
FIGURA A.286: ME14T15R (RPROP-/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	162
FIGURA A.287: ME14T15R (RPROP-/Q). VALORES POR AMOSTRA C/ERRO>30%	162
FIGURA A.288: ME14T15R (RPROP-/Q). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	162
FIGURA A.289: ME14T15R (RPROP-/Q). MODELAÇÃO DO CONJ. DE TREINO.	162
FIGURA A.290: ME14T15R (RPROP-/Q). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	163
FIGURA A.291: ME14T15R (RPROP-/Q). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	163
FIGURA A.292: ME14T15R (RPROP+/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	163
FIGURA A.293: ME14T15R (RPROP+/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	163
FIGURA A.294: ME14T15R (RPROP+/Q). VALORES POR AMOSTRA C/ERRO>30%	164
FIGURA A.295: ME14T15R (RPROP+/Q). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	164
FIGURA A.296: ME14T15R (RPROP+/Q). MODELAÇÃO DO CONJ. DE TREINO.	164
FIGURA A.297: ME14T15R (RPROP+/Q). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	164
FIGURA A.298: ME14T15R (RPROP+/Q). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	164
FIGURA A.299: ME14T15R (SAG/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	165
FIGURA A.300: ME14T15R (SAG/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	165
FIGURA A.301: ME14T15R (SAG/Q). VALORES POR AMOSTRA C/ERRO>30%	165
FIGURA A.302: ME14T15R (SAG/Q). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	165
FIGURA A.303: ME14T15R (SAG/Q). MODELAÇÃO DO CONJ. DE TREINO.	165
FIGURA A.304: ME14T15R (SAG/Q). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	166
FIGURA A.305: ME14T15R (SAG/Q). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	166
FIGURA A.306: MEGLOBALR (RPROP-). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	166
FIGURA A.307: MEGLOBALR (RPROP-). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	166
FIGURA A.308: MEGLOBALR (RPROP-). VALORES POR AMOSTRA C/ERRO>30%	167
FIGURA A.309: MEGLOBALR (RPROP-). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	167
FIGURA A.310: MEGLOBALR (RPROP-). MODELAÇÃO DO CONJ. DE TREINO.	167

FIGURA A.311: MEGLOBALR (RPROP-). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	167
FIGURA A.312: MEGLOBALR (RPROP-). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	167
FIGURA A.313: MEGLOBALR (RPROP+). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	168
FIGURA A.314: MEGLOBALR (RPROP+). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	168
FIGURA A.315: MEGLOBALR (RPROP+). VALORES POR AMOSTRA C/ERRO>30%	168
FIGURA A.316: MEGLOBALR (RPROP+). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	168
FIGURA A.317: MEGLOBALR (RPROP+). MODELAÇÃO DO CONJ. DE TREINO.	168
FIGURA A.318: MEGLOBALR (RPROP+). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	169
FIGURA A.319: MEGLOBALR (RPROP+). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	169
FIGURA A.320: MEGLOBALR (SAG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	169
FIGURA A.321: MEGLOBALR (SAG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	169
FIGURA A.322: MEGLOBALR (SAG). VALORES POR AMOSTRA C/ERRO>30%	170
FIGURA A.323: MEGLOBALR (SAG). MODELAÇÃO DO CONJ. DE TREINO.	170
FIGURA A.324: MEGLOBALR (SAG). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	170
FIGURA A.325: MEGLOBALR (SAG). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	170
FIGURA A.326: MEGLOBALR (SAG). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	170
FIGURA A.327: MEGLOBALR (RPROP AVG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	171
FIGURA A.328: MEGLOBALR (RPROP AVG). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	171
FIGURA A.329: MEGLOBALR (RPROP AVG). VALORES POR AMOSTRA C/ERRO>30%	171
FIGURA A.330: MEGLOBALR (RPROP AVG). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	171
FIGURA A.331: MEGLOBALR (RPROP AVG). MODELAÇÃO DO CONJ. DE TREINO.	171
FIGURA A.332: MEGLOBALR (RPROP AVG). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	172
FIGURA A.333: MEGLOBALR (RPROP AVG). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	172
FIGURA A.334: MEGLOBALR (AVG6). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	172
FIGURA A.335: MEGLOBALR (AVG6). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	172
FIGURA A.336: MEGLOBALR (AVG6). VALORES POR AMOSTRA C/ERRO>30%	173
FIGURA A.337: MEGLOBALR (AVG6). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	173
FIGURA A.338: MEGLOBALR (AVG6). MODELAÇÃO DO CONJ. DE TREINO.	173
FIGURA A.339: MEGLOBALR (AVG6). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	173
FIGURA A.340: MEGLOBALR (AVG6). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	173
FIGURA A.341: MEGLOBALR (RPROP-/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	174
FIGURA A.342: MEGLOBALR (RPROP-/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%	174
FIGURA A.343: MEGLOBALR (RPROP-/Q). VALORES POR AMOSTRA C/ERRO>30%	174
FIGURA A.344: MEGLOBALR (RPROP-/Q). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	174
FIGURA A.345: MEGLOBALR (RPROP-/Q). MODELAÇÃO DO CONJ. DE TREINO.	174
FIGURA A.346: MEGLOBALR (RPROP-/Q). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	175
FIGURA A.347: MEGLOBALR (RPROP-/Q). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	175
FIGURA A.348: MEGLOBALR (RPROP+/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	175
FIGURA A.349: MEGLOBALR (RPROP+/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	175
FIGURA A.350: MEGLOBALR (RPROP+/Q). VALORES POR AMOSTRA C/ERRO>30%	176
FIGURA A.351: MEGLOBALR (RPROP+/Q). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	176
FIGURA A.352: MEGLOBALR (RPROP+/Q). MODELAÇÃO DO CONJ. DE TREINO.	176
FIGURA A.353: MEGLOBALR (RPROP+/Q). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	176
FIGURA A.354: MEGLOBALR (RPROP+/Q). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	176
FIGURA A.355: MEGLOBALR (SAG/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	177
FIGURA A.356: MEGLOBALR (SAG/Q). VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	177
FIGURA A.357: MEGLOBALR (SAG/Q). VALORES POR AMOSTRA C/ERRO>30%	177
FIGURA A.358: MEGLOBALR (SAG/Q). MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	177
FIGURA A.359: MEGLOBALR (SAG/Q). MODELAÇÃO DO CONJ. DE TREINO.	177
FIGURA A.360: MEGLOBALR (SAG/Q). MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	178
FIGURA A.361: MEGLOBALR (SAG/Q). NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	178
FIGURA A.362: ME13ADR. VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	181

FIGURA A.363: ME13ADR. VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	181
FIGURA A.364: ME13ADR. VALORES POR AMOSTRA C/ERRO>30%	181
FIGURA A.365: ME13ADR. MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	181
FIGURA A.366: ME13ADR. MODELAÇÃO DO CONJ. DE TREINO.	181
FIGURA A.367: ME13ADR. MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	182
FIGURA A.368: ME13ADR. NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	182
FIGURA A.369: ME14ADR. VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	182
FIGURA A.370: ME14ADR. VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	182
FIGURA A.371: ME14ADR. VALORES POR AMOSTRA C/ERRO>30%	183
FIGURA A.372: ME14ADR. MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	183
FIGURA A.373: ME14ADR. MODELAÇÃO DO CONJ. DE TREINO.	183
FIGURA A.374: ME14ADR. MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	183
FIGURA A.375: ME14ADR. NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	183
FIGURA A.376: ME15ADR. VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	184
FIGURA A.377: ME15ADR. VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	184
FIGURA A.378: ME15ADR. VALORES POR AMOSTRA C/ERRO>30%	184
FIGURA A.379: ME15ADR. MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	184
FIGURA A.380: ME15ADR. MODELAÇÃO DO CONJ. DE TREINO.	184
FIGURA A.381: ME15ADR. MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	185
FIGURA A.382: ME15ADR. NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	185
FIGURA A.383: ME13T14ADR. VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	185
FIGURA A.384: ME13T14ADR. VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	185
FIGURA A.385: ME13T14ADR. VALORES POR AMOSTRA C/ERRO>30%	186
FIGURA A.386: ME13T14ADR. MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	186
FIGURA A.387: ME13T14ADR. MODELAÇÃO DO CONJ. DE TREINO.	186
FIGURA A.388: ME13T14ADR. MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	186
FIGURA A.389: ME13T14ADR. NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	186
FIGURA A.390: ME14T15ADR. VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	187
FIGURA A.391: ME14T15ADR. VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	187
FIGURA A.392: ME14T15ADR. VALORES POR AMOSTRA C/ERRO>30%	187
FIGURA A.393: ME14T15ADR. MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	187
FIGURA A.394: ME14T15ADR. MODELAÇÃO DO CONJ. DE TREINO.	187
FIGURA A.395: ME14T15ADR. MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	188
FIGURA A.396: ME14T15ADR. NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	188
FIGURA A.397: MEGLOBALADR. VALORES E MÉDIAS POR AMOSTRA C/ERRO<30%.	188
FIGURA A.398: MEGLOBALADR. VALORES E MÉDIAS POR AMOSTRA C/ERRO<20%.	188
FIGURA A.399: MEGLOBALADR. VALORES POR AMOSTRA C/ERRO>30%	188
FIGURA A.400: MEGLOBALADR. MODELAÇÃO DO CONJ. DE TESTE. (PREV. VS REAL)	189
FIGURA A.401: MEGLOBALADR. MODELAÇÃO DO CONJ. DE TREINO.	189
FIGURA A.402: MEGLOBALADR. MODELAÇÃO DO CONJ. DE TREINO. (PREV. VS REAL)	189
FIGURA A.403: MEGLOBALADR. NÚMERO DE AMOSTRAS POR CATEGORIA DE ERRO	189
FIGURA A.404: ME13ADR TOPOLOGIA DA ÁRVORE DE DECISÃO	192
FIGURA A.405: ME14ADR TOPOLOGIA DA ÁRVORE DE DECISÃO	193
FIGURA A.406: ME15ADR TOPOLOGIA DA ÁRVORE DE DECISÃO	194
FIGURA A.407: ME13T14ADR TOPOLOGIA DA ÁRVORE DE DECISÃO	195
FIGURA A.408: ME14T15ADR TOPOLOGIA DA ÁRVORE DE DECISÃO	196
FIGURA A.409: MEGLOBALADR TOPOLOGIA DA ÁRVORE DE DECISÃO	197

## Lista de Tabelas (Anexos)

TABELA A-1: DISTRIBUIÇÃO DA SOMA ABSOLUTA DAS RESPOSTAS	20
TABELA A-2: CATEGORIAS MEDIANTE O DELTA DOS RESULTADOS FINANCEIROS	21
TABELA A-3: INFORMAÇÃO SOBRE DADOS DA TABELA A-4	22
TABELA A-4: INFORMAÇÃO SOBRE RENDIMENTOS DE PARTICULARES	23
TABELA A-5: INFORMAÇÃO SOBRE DADOS DA TABELA A-8	23
TABELA A-6: INFORMAÇÃO SOBRE DADOS DA TABELA A-8	24
TABELA A-7: INFORMAÇÃO SOBRE DADOS DA TABELA A-8	24
TABELA A-8: INFORMAÇÃO SOBRE MERCADO DE EMPREGO E CONSUMO PRIVADO	25
TABELA A-9: INFORMAÇÃO SOBRE DADOS DA TABELA A-10	25
TABELA A-10: INFORMAÇÕES SOBRE AMBIENTE ECONÓMICO EM PORTUGAL	27
TABELA A-11: INFORMAÇÕES SOBRE O AMBIENTE ECONÓMICO EM PORTUGAL - PIB: VOLUME E VARIAÇÃO.	27
TABELA A-12: INFORMAÇÃO SOBRE DADOS DA TABELA A-15	28
TABELA A-13: INFORMAÇÃO SOBRE DADOS DA TABELA A-15	28
TABELA A-14: INFORMAÇÃO SOBRE DADOS DA TABELA A-15	28
TABELA A-15: INFORMAÇÕES SOBRE ÍNDICE INDUSTRIAL E CONFIANÇA	31
TABELA A-16: INFORMAÇÃO SOBRE DADOS DA TABELA A-17	32
TABELA A-17: INFORMAÇÕES SOBRE PATRIMÓNIOS ANUAIS CONSOLIDADOS	32
TABELA A-18: INFORMAÇÃO SOBRE DADOS DA TABELA A-20	32
TABELA A-19: LEGENDA SOBRE DADOS DA TABELA A-26	33
TABELA A-20: INFORMAÇÕES SOBRE ÍNDICE DE PREÇOS NO CONSUMIDOR	35
TABELA A-21: INFORMAÇÃO SOBRE DADOS DA TABELA A-26	35
TABELA A-22: INFORMAÇÃO SOBRE DADOS DA TABELA A-26	35
TABELA A-23: INFORMAÇÃO SOBRE DADOS DA TABELA A-26	36
TABELA A-24: INFORMAÇÃO SOBRE DADOS DA TABELA A-26	36
TABELA A-25: INFORMAÇÃO SOBRE DADOS DA TABELA A-26	36
TABELA A-26: INFORMAÇÕES SOBRE EMPRÉSTICO, CRÉDITOS E DIVIDAS	37
TABELA A-27: INFORMAÇÃO TABELA TX JURO (NOVAS OPERAÇÕES). EMPRÉSTIMOS PARTICULARES. CONSUMO - TOTAL.	38
TABELA A-28: INFORMAÇÃO TABELA TX JURO (NOVAS OPERAÇÕES). EMPRÉSTIMOS PARTICULARES. CONSUMO - ATÉ 1 ANO.	38
TABELA A-29: INFORMAÇÃO TABELA TX JURO (NOVAS OPERAÇÕES). EMPRÉSTIMOS PARTICULARES. CONSUMO - DE 1 A 5 ANOS.	38
TABELA A-30: INFORMAÇÃO TABELA TX JURO (NOVAS OPERAÇÕES). EMPRÉSTIMOS PARTICULARES. CONSUMO - TAEG.	39
TABELA A-31: INFORMAÇÃO SOBRE TAXAS DE JURO DE EMPRÉSTIMOS A PARTICULARES	41
TABELA A-32: RESULTADOS PREVISÃO ATRAVÉS RNA (NET CONSOLE) ANO 2013	42
TABELA A-33: RESULTADOS PREVISÃO ATRAVÉS RNA (NET CONSOLE) ANO 2014	43
TABELA A-34: RESULTADOS PREVISÃO ATRAVÉS RNA (NET CONSOLE) ANO 2015	43
TABELA A-35: RESULTADOS PREVISÃO ATRAVÉS RNA (NET CONSOLE) CONJUNTO TREINO 2013 E CONJUNTO TESTE 2014	45
TABELA A-36: RESULTADOS PREVISÃO ATRAVÉS RNA (NET CONSOLE) CONJUNTO TREINO 2014 E CONJUNTO TESTE 2015	47
TABELA A-37: REDES NEURONAIS R - RESULTADOS DADOS 2013. MODELO ESTRATÉGICO ME13 (R)	49
TABELA A-38: REDES NEURONAIS R - RESULTADOS DADOS 2013. MODELO ESTRATÉGICO ME13T14 (R)	50
TABELA A-39: REDES NEURONAIS R - RESULTADOS DADOS 2013. MODELO ESTRATÉGICO MEGLOBAL (R)	51
TABELA A-40: REDES NEURONAIS R - RESULTADOS DADOS 2014. MODELO ESTRATÉGICO ME14 (R)	53
TABELA A-41: REDES NEURONAIS R - RESULTADOS DADOS 2014. MODELO ESTRATÉGICO ME13T14 (R)	55
TABELA A-42: REDES NEURONAIS R - RESULTADOS DADOS 2014. MODELO ESTRATÉGICO ME14T15 (R)	57
TABELA A-43: REDES NEURONAIS R - RESULTADOS DADOS 2014. MODELO ESTRATÉGICO MEGLOBAL(R)	58
TABELA A-44: REDES NEURONAIS R - RESULTADOS DADOS 2015. MODELO ESTRATÉGICO ME15 (R)	60

TABELA A-45: REDES NEURONAIS R - RESULTADOS DADOS 2015. MODELO ESTRATÉGICO ME14T15 (R)	62
TABELA A-46: REDES NEURONAIS R - RESULTADOS DADOS 2015. MODELO ESTRATÉGICO MEGLOBAL (R)	63
TABELA A-47: REDES NEURONAIS R - NÚMERO DE AMOSTRAS CATEGORIZADAS POR ERRO, MODELO E ALGORITMO..	65
TABELA A-48: REDES NEURONAIS R - PERCENTAGEM DE AMOSTRAS CATEGORIZADAS POR ERRO, MODELO E ALGORITMO..	67
TABELA A-49:REDES NEURONAIS R - ERROS, AMPLITUDES POR MODELO E ALGORITMO	69
TABELA A-50: ÁRVORE DE DECISÃO R - RESULTADOS MODELO ESTRATÉGICO ME13ADR	72
TABELA A-51: ÁRVORE DE DECISÃO R - RESULTADOS MODELO ESTRATÉGICO ME14ADR	75
TABELA A-52: ÁRVORE DE DECISÃO R - RESULTADOS MODELO ESTRATÉGICO ME15ADR	78
TABELA A-53: ÁRVORE DE DECISÃO R - RESULTADOS MODELO ESTRATÉGICO ME13T14ADR	84
TABELA A-54: ÁRVORE DE DECISÃO R - RESULTADOS MODELO ESTRATÉGICO ME14T15ADR	90
TABELA A-55: ÁRVORE DE DECISÃO R - RESULTADOS MODELO ESTRATÉGICO MEGLOBALADR	99
TABELA A-56: ÁRVORES DE DECISÃO R - MARIZ DE DESEMPENHO	100
TABELA A-57: ME13NC. NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	101
TABELA A-58: ME13NC. VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	102
TABELA A-59: ME14NC. NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	102
TABELA A-60: ME14NC. VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	103
TABELA A-61: ME15NC. NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	104
TABELA A-62: ME15NC. VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	104
TABELA A-63: ME13T14NC. NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	105
TABELA A-64: ME13T14NC. VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	105
TABELA A-65: ME14T15NC. NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	106
TABELA A-66: ME14T15NC. VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	106
TABELA A-67:ME13R (RProp-). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	107
TABELA A-68: ME13R (RProp-). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	107
TABELA A-69: ME13R (RProp+). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	109
TABELA A-70: ME13R (RProp+). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	109
TABELA A-71: ME13R (SAG). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	110
TABELA A-72: ME13R (SAG). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	110
TABELA A-73: ME13R (RProp AVG). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	112
TABELA A-74: ME13R (RProp AVG). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	112
TABELA A-75: ME13R (AVG6). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	113
TABELA A-76: ME13R (AVG6). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	113
TABELA A-77: ME13R (RProp-/Q). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	115
TABELA A-78: ME13R (RProp-/Q). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	115
TABELA A-79: ME13R (RProp+/Q). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	116
TABELA A-80: ME13R (RProp+/Q). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	116
TABELA A-81: ME13R (SAG/Q). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	118
TABELA A-82: ME13R (SAG/Q). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	118
TABELA A-83: ME14R (RProp-). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	119
TABELA A-84: ME14R (RProp-). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	119
TABELA A-85: ME14R (RProp+). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	121
TABELA A-86: ME14R (RProp+). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	121
TABELA A-87: ME14R (SAG). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	122
TABELA A-88: ME14R (SAG). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	122
TABELA A-89: ME14R (RProp AVG). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	124
TABELA A-90: ME14R (RProp AVG). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	124
TABELA A-91: ME14R (AVG6). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	125
TABELA A-92: ME14R (AVG6). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	125
TABELA A-93: ME14R (RProp-/Q). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	127
TABELA A-94: ME14R (RProp-/Q). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	127
TABELA A-95: ME14R (RProp+/Q). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	128

TABELA A-96: ME14R (RProp+/Q). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	128
TABELA A-97: ME14R (SAG/Q). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	130
TABELA A-98: ME14R (SAG/Q). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	130
TABELA A-99: ME15R (RProp-). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	131
TABELA A-100: ME15R (RProp-). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	131
TABELA A-101: ME15R (RProp+). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	133
TABELA A-102: ME15R (RProp+). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	133
TABELA A-103: ME15R (SAG). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	134
TABELA A-104: ME15R (SAG). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	134
TABELA A-105: ME15R (RProp AVG). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	136
TABELA A-106: ME15R (RProp AVG). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	136
TABELA A-107: ME15R (AVG6). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	137
TABELA A-108: ME15R (AVG6). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	137
TABELA A-109: ME15R (RProp-/Q). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	139
TABELA A-110: ME15R (RProp-/Q). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	139
TABELA A-111: ME15R (RProp+/Q). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	140
TABELA A-112: ME15R (RProp+/Q). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	140
TABELA A-113: ME15R (SAG/Q). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	142
TABELA A-114: ME15R (SAG/Q). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	142
TABELA A-115: ME13T14R (RProp-). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	143
TABELA A-116: ME13T14R (RProp-). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	143
TABELA A-117: ME13T14R (RProp+). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	145
TABELA A-118: ME13T14R (RProp+). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	145
TABELA A-119: ME13T14R (SAG). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	146
TABELA A-120: ME13T14R (SAG). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	146
TABELA A-121: ME13T14R (RProp AVG). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	148
TABELA A-122: ME13T14R (RProp AVG). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	148
TABELA A-123: ME13T14R (AVG6). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	149
TABELA A-124: ME13T14R (AVG6). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	149
TABELA A-125: ME13T14R (RProp-/Q). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	151
TABELA A-126: ME13T14R (RProp-/Q). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	151
TABELA A-127: ME13T14R (RProp+/Q). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	152
TABELA A-128: ME13T14R (RProp+/Q). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	152
TABELA A-129: ME13T14R (SAG/Q). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	154
TABELA A-130: ME13T14R (SAG/Q). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	154
TABELA A-131: ME14T15R (RProp-). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	155
TABELA A-132: ME14T15R (RProp-). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	155
TABELA A-133: ME14T15R (RProp+). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	157
TABELA A-134: ME14T15R (RProp+). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	157
TABELA A-135: ME14T15R (SAG). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	158
TABELA A-136: ME14T15R (SAG). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	158
TABELA A-137: ME14T15R (RProp AVG). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	160
TABELA A-138: ME14T15R (RProp AVG). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	160
TABELA A-139: ME14T15R (AVG6). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	161
TABELA A-140: ME14T15R (AVG6). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	161
TABELA A-141: ME14T15R (RProp-/Q). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	163
TABELA A-142: ME14T15R (RProp-/Q). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	163
TABELA A-143: ME14T15R (RProp+/Q). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	164
TABELA A-144: ME14T15R (RProp+/Q). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	164
TABELA A-145: ME14T15R (SAG/Q). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	166
TABELA A-146: ME14T15R (SAG/Q). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	166
TABELA A-147: MEGLOBALR (RProp-). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	167

TABELA A-148: MEGLOBALR (RPROP-). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	167
TABELA A-149: MEGLOBALR (RPROP+). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	169
TABELA A-150: MEGLOBALR (RPROP+). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	169
TABELA A-151: MEGLOBALR (SAG). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	170
TABELA A-152: MEGLOBALR (SAG). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	170
TABELA A-153: MEGLOBALR (RPROP AVG). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	172
TABELA A-154: MEGLOBALR (RPROP AVG). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	172
TABELA A-155: MEGLOBALR (AVG6). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	173
TABELA A-156: MEGLOBALR (AVG6). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	173
TABELA A-157: MEGLOBALR (RPROP-/Q). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	175
TABELA A-158: MEGLOBALR (RPROP-/Q). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	175
TABELA A-159: MEGLOBALR (RPROP+/Q). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	176
TABELA A-160: MEGLOBALR (RPROP+/Q). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	176
TABELA A-161: MEGLOBALR (SAG/Q). NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	178
TABELA A-162: MEGLOBALR (SAG/Q). VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	178
TABELA A-163: TABELA GLOBAL DE AVALIAÇÃO (PARTE I)	179
TABELA A-164: TABELA DE AVALIAÇÃO GLOBAL (PARTE II)	180
TABELA A-165: ME13ADR. NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	182
TABELA A-166: ME13ADR. VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	182
TABELA A-167: ME14ADR. NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	183
TABELA A-168: ME14ADR. VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	183
TABELA A-169: ME15ADR. NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	185
TABELA A-170: ME15ADR. VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	185
TABELA A-171: ME13T14ADR. NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	186
TABELA A-172: ME13T14ADR. VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	186
TABELA A-173: ME14T15ADR. NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	188
TABELA A-174: ME14T15ADR. VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	188
TABELA A-175: MEGLOBALADR. NÚMERO E % DE AMOSTRAS POR CATEGORIA DE ERRO.	189
TABELA A-176: MEGLOBALADR. VALOR E % DO ERRO MÉDIO E AMPLITUDE DE RESULTADOS	189
TABELA A-177: TABELA DE AVALIAÇÃO GLOBAL ADS	191



## A ANEXOS

### A.1 Questionário

#### A.1.1 Formulação

A estratégia de aumento ou diminuição de preços deve providenciar uma otimização nos resultados do volume de negócios. Isto é, com o aumento de preços, embora possa existir uma quebra no número de vendas, ainda assim compensar no volume de negócios total ou, pelo menos, nos resultados operacionais. Geralmente com a diminuição do preço pretende-se focar o objetivo da estratégia no aumento do número de vendas e por conseguinte no aumento do volume de negócios.

Aumento de preços? (Exclui diminuição de preços)

	Nível de aplicação										Nível de sucesso									
	0	1	2	3	4	5	6	7	8	9	0	1	2	3	4	5	6	7	8	9
Ano 2013	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Ano 2014	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Ano 2015	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

Diminuição de preços? (Exclui aumento de preços)

	Nível de aplicação										Nível de sucesso									
	0	1	2	3	4	5	6	7	8	9	0	1	2	3	4	5	6	7	8	9
Ano 2013	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Ano 2014	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Ano 2015	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

A aplicação de estratégias como aumento ou diminuição de qualidade de serviços/produtos, pode dar uma vantagem competitiva em relação aos seus concorrentes. Geralmente estas estratégias vêm acompanhadas com um aumento ou redução no preço. Mesmo a diminuição de qualidade pode ser importante na sobrevivência da organização, uma vez que uma qualidade excessiva pode não ter impacto na satisfação do cliente mas ter um impacto significativo nos custos tornando-os excessivos.

Aumento de qualidade produtos/serviços? (Exclui diminuição de qualidade)

	Nível de aplicação										Nível de sucesso									
	0	1	2	3	4	5	6	7	8	9	0	1	2	3	4	5	6	7	8	9
Ano 2013	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Ano 2014	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Ano 2015	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

Diminuição de qualidade produtos/serviços? (Exclui aumento de qualidade)																					
Nível de aplicação											Nível de sucesso										
	0	1	2	3	4	5	6	7	8	9		0	1	2	3	4	5	6	7	8	9
Ano 2013	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>		<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Ano 2014	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>		<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Ano 2015	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>		<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

A diminuição de custo de pessoal é uma das estratégias mais utilizadas hoje em dia para diminuição dos custos operacionais ou administrativos. Nesta categoria encontra-se a redução de pessoal, através de despedimentos ou a não renovação de contratos, ou ainda a não atribuição de prémios ou diminuição de benefícios, como por exemplo o usufruto de automóvel da empresa para motivos pessoais.

Diminuição com Custos de Pessoal?

Nível de aplicação											Nível de sucesso										
	0	1	2	3	4	5	6	7	8	9		0	1	2	3	4	5	6	7	8	9
Ano 2013	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>		<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Ano 2014	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>		<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Ano 2015	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>		<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

A definição de estratégias que implicam um aumento de investimento pode estar inerente à aquisição de máquinas de produção, assim como a ferramentas tecnológicas, que visam à melhoria de processos e/ou produtos que permitam uma otimização da produção, assim como uma aumento da capacidade produtiva.

Aumento de investimento?

Nível de aplicação											Nível de sucesso										
	0	1	2	3	4	5	6	7	8	9		0	1	2	3	4	5	6	7	8	9
Ano 2013	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>		<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Ano 2014	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>		<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Ano 2015	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>		<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

As estratégias que visam a diminuição de financiamento estão inerentes à pretensão de diminuir os gastos de financiamento, com por exemplo a diminuição de dívidas com amortizações extraordinárias, quer a partir de aumentos de capital, quer a partir de resultados líquidos da organização

Diminuição de financiamento?

Nível de aplicação											Nível de sucesso										
	0	1	2	3	4	5	6	7	8	9		0	1	2	3	4	5	6	7	8	9
Ano 2013	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>		<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Ano 2014	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>		<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Ano 2015	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>		<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

A diversificação ou especialização de produtos/serviços é uma estratégia utilizada por parte das organizações de forma a providenciarem serviços especializados, ou seja deixam de ter outros produtos ou serviços que não são rentáveis. Ou por outro lado de diversificarem os seus produtos e serviços para atingirem um mercado mais amplo e assim conseguirem um maior número de clientes.

Diversificação de produtos/serviços? (Exclusão com especialização)

Nível de aplicação											Nível de sucesso										
	0	1	2	3	4	5	6	7	8	9		0	1	2	3	4	5	6	7	8	9
Ano 2013	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>		<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Ano 2014	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>		<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Ano 2015	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>		<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

Especialização de produtos/serviços? (Exclusão com diversificação)

Nível de aplicação											Nível de sucesso										
	0	1	2	3	4	5	6	7	8	9		0	1	2	3	4	5	6	7	8	9
Ano 2013	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>		<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Ano 2014	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>		<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Ano 2015	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>		<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>



As estratégias inerentes à redução ou aumento de clientes ou mercados visam por sua vez, no caso de a redução, deixarem de estar presentes em mercados ou disponíveis para um certo tipo de clientes que não têm rentabilidade. Esta estratégia poder estar associada a segmentos de mercado mas também à demografia dos mercados. Por exemplo ter um serviço no distrito de Lisboa e no distrito de Leiria e optar por só ter esse serviço no distrito de Lisboa, por o distrito de Leiria não dar rentabilidade à organização. Da mesma forma o aumento de clientes ou mercados pode trazer mais-valias à organização, caso tornem esses mercados rentáveis.

Redução de clientes/mercados? (Exclusão com aumento de mercados/clientes)

Nível de aplicação											Nível de sucesso										
	0	1	2	3	4	5	6	7	8	9		0	1	2	3	4	5	6	7	8	9
Ano 2013	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>		<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Ano 2014	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>		<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Ano 2015	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>		<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

Aumento de clientes/mercados? (Exclusão com redução de mercados/clientes)

Nível de aplicação											Nível de sucesso										
	0	1	2	3	4	5	6	7	8	9		0	1	2	3	4	5	6	7	8	9
Ano 2013	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>		<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Ano 2014	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>		<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Ano 2015	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>		<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

As estratégias que permitem sinergias com parceiros comerciais assentam nas parcerias estratégicas com outras organizações que permitam um aumento de clientes derivados da necessidade de serviços complementares. Por exemplo quando uma organização A que vende um certo tipo de serviços e precisa de um certo tipo de produtos faz uma parceria com a organização B que vende esses produtos e em que os seus clientes por vezes necessitam dos serviços da organização A. Geralmente estas parcerias encontram-se em empresas que trabalham apenas com uma ou duas marcas de produtos.

Sinergias com parceiros comerciais?

Nível de aplicação											Nível de sucesso										
	0	1	2	3	4	5	6	7	8	9		0	1	2	3	4	5	6	7	8	9
Ano 2013	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>		<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Ano 2014	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>		<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Ano 2015	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>		<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

A aplicação de estratégias de marketing e publicidade tem um papel importante na angariação de clientes, tal como na criação de valor através da imagem da organização. Com este tópico pretende-se saber se existiu uma análise cuidada para a divulgação dos serviços/produtos e qual o sucesso, mediante os objetivos, que essa estratégia protagonizou. Nesta estratégia estão incluídas promoções ou divulgação nas redes sociais.

Divulgação de produtos/serviços?

Nível de aplicação											Nível de sucesso										
	0	1	2	3	4	5	6	7	8	9		0	1	2	3	4	5	6	7	8	9
Ano 2013	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>		<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Ano 2014	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>		<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Ano 2015	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>		<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

A reorganização empresarial é uma estratégia que implica alterações organizacionais de forma a melhorar processos ou a diminuir custos com pessoal. Nesta categoria encontra-se a mudança de funções de pessoal como a transição de um departamento para outro, de forma a transferir pessoal de onde exista pouco trabalho para onde exista escassez de mão de obra. Outro ponto que pode estar inerente a esta estratégia é a criação ou remoção de postos de chefia consoante as necessidades da organização.

Reorganização empresarial?

Nível de aplicação											Nível de sucesso										
	0	1	2	3	4	5	6	7	8	9		0	1	2	3	4	5	6	7	8	9
Ano 2013	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>		<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Ano 2014	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>		<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Ano 2015	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>		<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

A renegociação com fornecedores pode ter um impacto significativo nos resultados operacionais. Algumas das estratégias inerentes a este tópico é a renegociação de preços, prazos de entrega ou mesmo a qualidade dos produtos/serviços.

Renegociação com fornecedores?

Nível de aplicação											Nível de sucesso										
	0	1	2	3	4	5	6	7	8	9		0	1	2	3	4	5	6	7	8	9
Ano 2013	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>		<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Ano 2014	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>		<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Ano 2015	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>		<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

Save

## A.1.2 Dados

Soma Abs	2013	2014	2015	Soma Abs	2013	2014	2015	Soma Abs	2013	2014	2015
0	30	27	27	34	16	9	7	68	0	2	1
1	2	1	0	35	6	7	11	69	1	2	5
2	5	3	2	36	9	13	10	70	1	2	1
3	6	4	4	37	4	6	5	71	2	0	1
4	5	2	3	38	9	12	11	72	0	1	2
5	7	5	2	39	7	11	5	73	2	0	3
6	8	3	2	40	8	11	10	74	1	1	2
7	7	5	4	41	6	6	8	75	0	1	1
8	8	7	4	42	5	4	7	76	0	0	1
9	8	8	9	43	0	4	10	77	0	0	0
10	6	9	10	44	7	6	2	78	0	0	1
11	7	6	0	45	6	5	8	79	1	1	1
12	9	10	3	46	10	7	10	80	0	0	0
13	9	7	5	47	6	9	7	81	0	0	1
14	4	1	5	48	3	5	8	82	0	1	0
15	11	12	12	49	11	9	12	83	0	0	0
16	13	5	3	50	3	9	6	84	0	0	0
17	5	11	8	51	4	4	4	85	0	0	0
18	6	4	10	52	4	6	10	86	0	0	0
19	9	2	4	53	1	8	7	87	0	0	0
20	4	7	5	54	5	6	4	88	0	0	1
21	5	6	8	55	8	8	5	89	0	0	0
22	3	6	2	56	4	9	9	90	0	0	0
23	7	4	3	57	5	4	6	91	0	0	0
24	5	5	4	58	4	7	5	92	0	0	0
25	12	6	4	59	0	3	8	93	0	0	0
26	8	4	5	60	1	0	6	94	0	0	0
27	11	8	6	61	2	1	4	95	0	0	0
28	4	7	3	62	1	2	5	96	0	0	0
29	15	12	8	63	1	0	4	97	0	1	0
30	11	6	9	64	2	4	3	98	1	0	0
31	8	12	6	65	2	2	6	99	0	0	1
32	10	13	11	66	1	1	2				
33	10	10	7	67	0	0	3	Soma	448	448	448

Tabela A-1: Distribuição da soma absoluta das respostas

Valor	Categoria	Valor	Categoria	Valor	Categoria	Valor	Categoria	Valor	Categoria
0	0	0.5	0.5	1	1	1.5	1.5	2	2
0.01	0	0.51	0.5	1.01	1	1.51	1.5	2.01	2
0.02	0	0.52	0.5	1.02	1	1.52	1.5	2.02	2
0.03	0.05	0.53	0.55	1.03	1.05	1.53	1.55	2.03	2.05
0.04	0.05	0.54	0.55	1.04	1.05	1.54	1.55	2.04	2.05
0.05	0.05	0.55	0.55	1.05	1.05	1.55	1.55	2.05	2.05
0.06	0.05	0.56	0.55	1.06	1.05	1.56	1.55	2.06	2.05
0.07	0.05	0.57	0.55	1.07	1.05	1.57	1.55	2.07	2.05
0.08	0.1	0.58	0.6	1.08	1.1	1.58	1.6	2.08	2.1
0.09	0.1	0.59	0.6	1.09	1.1	1.59	1.6	2.09	2.1
0.1	0.1	0.6	0.6	1.1	1.1	1.6	1.6	2.1	2.1
0.11	0.1	0.61	0.6	1.11	1.1	1.61	1.6	2.11	2.1
0.12	0.1	0.62	0.6	1.12	1.1	1.62	1.6	2.12	2.1
0.13	0.15	0.63	0.65	1.13	1.15	1.63	1.65	2.13	2.15

## ANEXOS- Dados Económicos

Valor	Categoria	Valor	Categoria	Valor	Categoria	Valor	Categoria	Valor	Categoria
0.14	0.15	0.64	0.65	1.14	1.15	1.64	1.65	2.14	2.15
0.15	0.15	0.65	0.65	1.15	1.15	1.65	1.65	2.15	2.15
0.16	0.15	0.66	0.65	1.16	1.15	1.66	1.65	2.16	2.15
0.17	0.15	0.67	0.65	1.17	1.15	1.67	1.65	2.17	2.15
0.18	0.2	0.68	0.7	1.18	1.2	1.68	1.7	2.18	2.2
0.19	0.2	0.69	0.7	1.19	1.2	1.69	1.7	2.19	2.2
0.2	0.2	0.7	0.7	1.2	1.2	1.7	1.7	2.2	2.2
0.21	0.2	0.71	0.7	1.21	1.2	1.71	1.7	2.21	2.2
0.22	0.2	0.72	0.7	1.22	1.2	1.72	1.7	2.22	2.2
0.23	0.25	0.73	0.75	1.23	1.25	1.73	1.75	2.23	2.25
0.24	0.25	0.74	0.75	1.24	1.25	1.74	1.75	2.24	2.25
0.25	0.25	0.75	0.75	1.25	1.25	1.75	1.75	2.25	2.25
0.26	0.25	0.76	0.75	1.26	1.25	1.76	1.75	2.26	2.25
0.27	0.25	0.77	0.75	1.27	1.25	1.77	1.75	2.27	2.25
0.28	0.3	0.78	0.8	1.28	1.3	1.78	1.8	2.28	2.3
0.29	0.3	0.79	0.8	1.29	1.3	1.79	1.8	2.29	2.3
0.3	0.3	0.8	0.8	1.3	1.3	1.8	1.8	2.3	2.3
0.31	0.3	0.81	0.8	1.31	1.3	1.81	1.8	2.31	2.3
0.32	0.3	0.82	0.8	1.32	1.3	1.82	1.8	2.32	2.3
0.33	0.35	0.83	0.85	1.33	1.35	1.83	1.85	2.33	2.35
0.34	0.35	0.84	0.85	1.34	1.35	1.84	1.85	2.34	2.35
0.35	0.35	0.85	0.85	1.35	1.35	1.85	1.85	2.35	2.35
0.36	0.35	0.86	0.85	1.36	1.35	1.86	1.85	2.36	2.35
0.37	0.35	0.87	0.85	1.37	1.35	1.87	1.85	2.37	2.35
0.38	0.4	0.88	0.9	1.38	1.4	1.88	1.9	2.38	2.4
0.39	0.4	0.89	0.9	1.39	1.4	1.89	1.9	2.39	2.4
0.4	0.4	0.9	0.9	1.4	1.4	1.9	1.9	2.4	2.4
0.41	0.4	0.91	0.9	1.41	1.4	1.91	1.9	2.41	2.4
0.42	0.4	0.92	0.9	1.42	1.4	1.92	1.9	2.42	2.4
0.43	0.45	0.93	0.95	1.43	1.45	1.93	1.95	2.43	2.45
0.44	0.45	0.94	0.95	1.44	1.45	1.94	1.95	2.44	2.45
0.45	0.45	0.95	0.95	1.45	1.45	1.95	1.95	2.45	2.45
0.46	0.45	0.96	0.95	1.46	1.45	1.96	1.95	2.46	2.45
0.47	0.45	0.97	0.95	1.47	1.45	1.97	1.95	2.47	2.45
0.48	0.5	0.98	1	1.48	1.5	1.98	2	2.48	2.5
0.49	0.5	0.99	1	1.49	1.5	1.99	2	2.49	2.5

*Tabela A-2: Categorias mediante o delta dos resultados financeiros*

### A.2 Dados Económicos

Descrição	
CN Anuais - Rendimento dos particulares - Remunerações do trabalho	Contas Nacionais Anuais - Rendimento dos particulares - Remunerações do trabalho
CN Anuais - Rendimento dos particulares - Transferências internas	Contas Nacionais Anuais - Rendimento dos particulares - Transferências internas
CN Anuais - Rendimento dos particulares - Transferências externas	Contas Nacionais Anuais - Rendimento dos particulares - Transferências externas

## ANEXOS- Dados Económicos

Descrição	
CN Anuais - Rendimento dos particulares - Rendimentos de empresa e propriedade	Contas Nacionais Anuais - Rendimento dos particulares - Rendimentos de empresa e propriedade
CN Anuais - Rendimento dos particulares - Impostos directos	Contas Nacionais Anuais - Rendimento dos particulares - Impostos directos
CN Anuais - Rendimento dos particulares - Contribuições para a Segurança Social	Contas Nacionais Anuais - Rendimento dos particulares - Contribuições para a Segurança Social
CN Anuais - Rendimento dos particulares - Rendimento disponível	Contas Nacionais Anuais - Rendimento dos particulares - Rendimento disponível
Informação de referência	
Potenciação	10^6
Fonte	Instituto Nacional de Estatística e Banco de Portugal
Unidade de medida	Euros
Periodicidade	Anual
Natureza	Fluxos
Método de cálculo	Preços correntes
Método de conversão para periodicidade superior	Somatório

Tabela A-3: Informação sobre dados da Tabela A-4

	CN Anuais - Rendimento dos particulares - Remunerações do trabalho	CN Anuais - Rendimento dos particulares - Transferências internas	CN Anuais - Rendimento dos particulares - Transferências externas	CN Anuais - Rendimento dos particulares - Rendimentos de empresa e propriedade	CN Anuais - Rendimento dos particulares - Impostos directos	CN Anuais - Rendimento dos particulares - Contribuições para a Segurança Social	CN Anuais - Rendimento dos particulares - Rendimento disponível
	10^6	10^6	10^6	10^6	10^6	10^6	10^6
31/12/2018	90576.7	39564.2	4018.3	44900.3	13700.8	28132.8	137226
31/12/2017	86240.9	38131.8	3808.9	43889	13025.3	26704.7	132341
31/12/2016	81897.9	37428.3	3249.9	43808.5	12970.4	25299.3	128115
31/12/2015	78723.9	36494.8	3165.6	43697.4	13664.1	24263.3	124154
31/12/2014	76533	35650.8	3014.3	42500.2	13737.4	23895.1	120066
31/12/2013	76245.9	36212.6	3077.5	42071.3	13561.1	23777.6	120269
31/12/2012	75275	34451.3	2731.1	41059.4	10066.7	22958.3	120492
31/12/2011	81554	36545.7	2101.2	40588.7	10641.9	25163.9	124984
31/12/2010	84849.5	36319.5	1903.7	42248.1	9713.2	25857.5	129750
31/12/2009	83683.8	34888.1	1773.8	41098.6	9794	25468.9	126182
31/12/2008	83810.9	33135.1	2326.1	42878.2	9797.2	25649.6	126704
31/12/2007	81219.4	31414.6	2262.7	40776.1	9422.8	24466	121784
31/12/2006	77838.7	29979.3	2028.3	38655.7	8617.5	23694.8	116190



## ANEXOS- Dados Económicos

	CN Anuais - Rendimento dos particulares - Remunerações do trabalho	CN Anuais - Rendimento dos particulares - Transferências internas	CN Anuais - Rendimento dos particulares - Transferências externas	CN Anuais - Rendimento dos particulares - Rendimentos de empresa e propriedade	CN Anuais - Rendimento dos particulares - Impostos directos	CN Anuais - Rendimento dos particulares - Contribuições para a Segurança Social	CN Anuais - Rendimento dos particulares - Rendimento disponível
	10^6	10^6	10^6	10^6	10^6	10^6	10^6
31/12/2005	75699.1	27939.2	1707.3	37122.8	8145	22318.6	112005
31/12/2004	72338.3	26061.7	2074.9	35126.1	7792.7	20769.6	107039

Tabela A-4: Informação sobre rendimentos de particulares

Descrição	
CN Anuais - Mercado de Trabalho - Emprego	Contas Nacionais Anuais - Mercado de Trabalho - Emprego (milhares de indivíduos equivalentes a tempo completo - o emprego a tempo completo é definido como o número de horas trabalhadas, dividido pelo número médio anual de horas trabalhadas no trabalho a t
CN Anuais - Mercado de Trabalho - Trabalhadores por conta de outrem	Contas Nacionais Anuais - Mercado de Trabalho - Trabalhadores por conta de outrem (milhares de indivíduos equivalentes a tempo completo - o emprego a tempo completo é definido como o número de horas trabalhadas, dividido pelo número médio anual de horas t
CN Anuais - Mercado de Trabalho - Outras formas de emprego	Contas Nacionais Anuais - Mercado de Trabalho - Outras formas de emprego (milhares de indivíduos equivalentes a tempo completo - o emprego a tempo completo é definido como o número de horas trabalhadas, dividido pelo número médio anual de horas trabalhada
Informação de referência	
Potenciação	10^3
Fonte	Instituto Nacional de Estatística e Banco de Portugal
Unidade de medida	Unidades
Periodicidade	Anual
Natureza	Stock
Método de cálculo	Valores Brutos
Método de conversão para periodicidade superior	Média

Tabela A-5: Informação sobre dados da Tabela A-8

Descrição	
CN Anuais - Mercado de trabalho - Remuneração por trabalhador	CN Anuais - Mercado de trabalho - Remuneração por trabalhador
Informação de referência	
Potenciação	10^3
Fonte	Instituto Nacional de Estatística e Banco de Portugal
Unidade de medida	Euros

## ANEXOS- Dados Económicos

Descrição	
Periodicidade	Anual
Natureza	Fluxos
Método de cálculo	Preços correntes
Método de conversão para periodicidade superior	Somatório

Tabela A-6: Informação sobre dados da Tabela A-8

Descrição	
CN Anuais (preços correntes) - Consumo privado	Contas Nacionais Anuais (preços correntes) - Consumo privado
CN Anuais (preços correntes) - Consumo privado - duradouros	Contas Nacionais Anuais (preços correntes) - Consumo privado - duradouros
CN Anuais (preços correntes) - Consumo privado - não duradouros	Contas Nacionais Anuais (preços correntes) - Consumo privado - não duradouros
Informação de referência	
Potenciação	10 <sup>6</sup>
Fonte	Instituto Nacional de Estatística e Banco de Portugal
Unidade de medida	Euros
Periodicidade	Anual
Natureza	Fluxos
Método de cálculo	Preços correntes
Método de conversão para periodicidade superior	Somatório

Tabela A-7: Informação sobre dados da Tabela A-8

	CN Anuais - Mercado de Trabalho - Emprego	CN Anuais - Mercado de Trabalho - Trabalhadores por conta de outrem	CN Anuais - Mercado de Trabalho - Outras formas de emprego	CN Anuais - Mercado de Trabalho - Remuneração por trabalhador	CN Anuais (preços correntes) - Consumo privado	CN Anuais (preços correntes) - Consumo privado - duradouros	CN Anuais (preços correntes) - Consumo privado - não duradouros
	10 <sup>3</sup>	10 <sup>3</sup>	10 <sup>3</sup>	10 <sup>3</sup>	10 <sup>6</sup>	10 <sup>6</sup>	10 <sup>6</sup>
31/12/2018	4671.3	4094.2	577.1	22.123	130938	11903.6	119034
31/12/2017	4564.8	3978.9	585.8	21.674	126159	11396.7	114762
31/12/2016	4419.9	3839.5	580.3	21.33	121789	10735.7	111053
31/12/2015	4327.5	3743.1	584.4	21.032	117727	9630.5	108096
31/12/2014	4246.7	3657.6	589.1	20.924	114060	8363	105697
31/12/2013	4178.8	3582.1	596.7	21.285	111144	7135.6	104008
31/12/2012	4285.7	3657.1	628.6	20.583	111610	7107.7	104502
31/12/2011	4527.7	3871.3	656.4	21.066	115961	9311.6	106650
31/12/2010	4644.6	3976.4	668.3	21.338	118329	11164.5	107165

# ANEXOS- Dados Económicos

	CN Anuais - Mercado de Trabalho - Emprego	CN Anuais - Mercado de Trabalho - Trabalhadores por conta de outrem	CN Anuais - Mercado de Trabalho - Outras formas de emprego	CN Anuais - Mercado de trabalho - Remuneração por trabalhador	CN Anuais (preços correntes) - Consumo privado	CN Anuais (preços correntes) - Consumo privado - duradouros	CN Anuais (preços correntes) - Consumo privado - não duradouros
	10 <sup>3</sup>	10 <sup>3</sup>	10 <sup>3</sup>	10 <sup>3</sup>	10 <sup>6</sup>	10 <sup>6</sup>	10 <sup>6</sup>
31/12/2009	4698.5	3995.9	702.6	20.943	113509	9821.6	103687
31/12/2008	4836.7	4093.9	742.8	20.472	118490	11866.5	106624
31/12/2007	4825.2	4076.1	749.1	19.926	113713	11925.4	101787
31/12/2006	4829.8	4061.5	768.2	19.165	107303	11354.7	95948.6
31/12/2005	4828.4	4033.3	795	18.768	102106	10902.9	91202.6
31/12/2004	4846.1	4029.8	816.3	17.951	96803	10165.4	86637.3

Tabela A-8: Informação sobre mercado de emprego e consumo privado

Descrição	Contas nacionais trimestrais (dados encadeados em volume - ref. 2006; corrigidos da sazonalidade)
PIB	Produto interno bruto - taxa de variação homóloga
Consumo privado (volume) - t.v.h. - Portugal	Despesas de consumo final - famílias residentes e ISFLSF
Consumo público (volume) - t.v.h. - Portugal	Despesas de consumo final - Administrações públicas
Procura interna (volume) - t.v.h. - Portugal	Procura interna (inclui variação de stocks)
Exportações (volume) - t.v.h. - Portugal	Exportações (f.o.b.)
Importações (volume) - t.v.h. - Portugal	Importações (f.o.b.)
Taxa de poupança dos particulares (em % do rendimento disponível)	Taxa de poupança bruta das famílias e ISFLSF em % do rendimento disponível; inclui ajustamento pela variação de participação líquida das famílias nos fundos de pensões. Ano terminado em cada trimestre.
Informação de referência	
Fonte	Instituto Nacional de Estatística
Unidade de medida	Porcentagem
Periodicidade	Trimestral
Método de cálculo	Taxa de variação homóloga
Método de conversão para periodicidade superior	N/A

Tabela A-9: Informação sobre dados da Tabela A-10

## ANEXOS- Dados Económicos

	PIB (volume) - t.v.h. - Portugal	Consumo privado (volume) - t.v.h. - Portugal	Consumo público (volume) - t.v.h. - Portugal	Procura interna (volume) - t.v.h. - Portugal	Exportações (volume) - t.v.h. - Portugal	Importações (volume) - t.v.h. - Portugal	Taxa de poupança dos particulares (em % do rendimento disponível)
	(%)	(%)	(%)	(%)	(%)	(%)	(%)
31/03/2019	1.8	2.5	0.4	4.1	3.7	8.5	4.5
31/12/2018	1.7	2.9	0.7	3.2	0.6	3.8	4.6
30/09/2018	2.1	2.4	0.8	2.5	2.9	3.5	4.1
30/06/2018	2.5	2.8	1.1	2.8	6.8	7.3	4.5
31/03/2018	2.3	2.3	0.9	2.5	4.5	5	4.6
31/12/2017	2.5	2.2	0.7	2.7	7.2	7.2	4.7
30/09/2017	2.5	2.7	0.6	3.7	6.2	8.7	4
30/06/2017	3.1	2	-0.3	2.9	8.2	7.7	4.7
31/03/2017	3.1	2.5	-0.1	2.8	9.7	8.9	4.3
31/12/2016	2.8	3.3	0.2	3.2	6.7	7.9	5
30/09/2016	2.3	2.1	0.4	1.9	5.4	4.6	5.2
30/06/2016	1.3	1.6	0.9	1	1.9	1.5	4.9
31/03/2016	1.3	2.6	1.7	1.8	3.4	4.7	5
31/12/2015	1.6	1.7	1.8	2.4	3.5	5.7	5.3
30/09/2015	1.9	2	1.6	2.3	5.6	6.8	5.1
30/06/2015	1.9	3.2	1.6	4.1	7.8	13.3	5.2
31/03/2015	1.9	2.3	0.1	2.1	7.8	8.4	5.4
31/12/2014	0.7	2.1	-1	1.7	6.2	8.8	5.2
30/09/2014	1	2.8	0.1	2.2	3.8	6.9	6.4
30/06/2014	0.7	2	-0.4	1.4	3.2	5	6.5
31/03/2014	1	2.3	-0.5	3.4	4.2	10.5	6.9
31/12/2013	1.9	1.6	-0.5	1	9.9	7.7	7.8
30/09/2013	-0.8	-0.5	-2.3	-0.8	7.9	7.9	8.8
30/06/2013	-1.7	-1.8	-2.7	-1.9	7.4	7	9
31/03/2013	-3.8	-3.9	-2.4	-6	2.7	-3.5	8.4
31/12/2012	-4.5	-5.1	-2.7	-5.5	0	-3	7.7
30/09/2012	-4.4	-5.7	-3.2	-7.5	2.5	-6.5	7.8
30/06/2012	-4.1	-5.7	-3.7	-8.7	3.8	-9.6	7.4
31/03/2012	-3.2	-5.5	-3.5	-7.5	7.6	-6	7.6
31/12/2011	-3.5	-6.2	-3.8	-9.7	6.5	-12.4	7.5
30/09/2011	-2.2	-3.4	-3.9	-5.1	6.1	-3.9	7.4
30/06/2011	-1.3	-3.2	-3.7	-5.3	7.8	-5.5	7.9
31/03/2011	-0.3	-1.6	-3.9	-2.6	7.8	-1	8.8
31/12/2010	1.4	1.7	-3.3	1.1	8.9	6.3	9.2

# ANEXOS- Dados Económicos

	PIB (volume) - t.v.h. - Portugal	Consumo privado (volume) - t.v.h. - Portugal	Consumo público (volume) - t.v.h. - Portugal	Procura interna (volume) - t.v.h. - Portugal	Exportações (volume) - t.v.h. - Portugal	Importações (volume) - t.v.h. - Portugal	Taxa de poupança dos particulares (em % do rendimento disponível)
	(%)	(%)	(%)	(%)	(%)	(%)	(%)
30/09/2010	1.7	2.1	-2.2	0.4	8.8	3.7	9.5
30/06/2010	2.5	3.4	-0.4	4	10.2	13.1	10.2
31/03/2010	2	2.4	0.7	2.1	10.3	8.6	10.6

Tabela A-10: Informações sobre ambiente económico em Portugal

	PIB	Variação
	10^9 Euros	%
2006	166.2	
2007	175.4	5.54%
2008	179.1	2.11%
2009	175.4	-2.07%
2010	179.6	2.39%
2011	176.1	-1.95%
2012	168.3	-4.43%
2013	170.5	1.31%
2014	173.1	1.52%
2015	179.7	3.81%
2016	186.5	3.78%
2017	195.9	5.04%
2018	203.9	4.08%

Tabela A-11: Informações sobre o ambiente económico em Portugal - PIB: Volume e variação.

IPI - Total excl. Construção - t.v.h. - Portugal	Índice de produção industrial para Portugal - Total excluindo Construção - taxa de variação em relação ao mesmo período do ano anterior
IPI - Bens de consumo - t.v.h. - Portugal	Índice de produção industrial para Portugal - Bens de consumo - taxa de variação em relação ao mesmo período do ano anterior
IPI - Bens intermédios - t.v.h. - Portugal	Índice de produção industrial para Portugal - Bens intermédios - taxa de variação em relação ao mesmo período do ano anterior
IPI - Energia - t.v.h. - Portugal	Índice de produção industrial para Portugal - Energia - taxa de variação em relação ao mesmo período do ano anterior
IVNCR (Índice Global) - Volume - t.v.h. - Portugal	Índice de volume de negócios no comércio a retalho - taxa de variação em relação ao mesmo período do ano anterior
Informação de referência	
Fonte	Instituto Nacional de Estatística

## ANEXOS- Dados Económicos

Unidade de medida	Percentagem
Periodicidade	Mensal
Natureza	N/A
Método de cálculo	Taxa de variação homóloga
Método de conversão para periodicidade superior	N/A

*Tabela A-12: Informação sobre dados da Tabela A-15*

Matrículas de veículos - passageiros - t.v.h. - Portugal	Matrículas de veículos de passageiros - taxa de variação em relação ao mesmo período do ano anterior
Informação de referência	
Fonte	Associação do Comércio Automóvel de Portugal
Unidade de medida	Percentagem
Periodicidade	Mensal
Natureza	N/A
Método de cálculo	Taxa de variação homóloga
Método de conversão para periodicidade superior	N/A

*Tabela A-13: Informação sobre dados da Tabela A-15*

Indicador de sentimento económico - Portugal	
Indicador de confiança dos consumidores - Portugal	
Indicador de confiança na indústria - Portugal	
Informação de referência	
Fonte	Comissão Europeia
Unidade de medida	Percentagem
Periodicidade	Mensal
Natureza	N/A
Método de cálculo	Valor corrigido de sazonalidade
Método de conversão para periodicidade superior	N/A
Nota: Índice de sentimento económico não tem unidades	

*Tabela A-14: Informação sobre dados da Tabela A-15*

## ANEXOS- Dados Económicos

	IPI - Total excl. Construção - t.v.h. - Portugal	IPI - Bens de consumo - t.v.h. - Portugal	IPI - Bens intermédios - t.v.h. - Portugal	IPI - Bens de investimento - t.v.h. - Portugal	IPI - Energia - t.v.h. - Portugal	IVNCR (Índice Global) - Volume - t.v.h. - Portugal	Matrículas de veículos - passageiros - t.v.h. - Portugal	Indicador de sentimento económico - Portugal	Indicador de confiança dos consumidores - Portugal	Indicador de confiança na indústria - Portugal
	(%)	(%)	(%)	(%)	(%)	(%)	(%)	Índice	(%)	(%)
31/12/2018	-1.6	-3.9	-3.1	4.2	-0.1	4.2	8.9	110.5	-6.6	-1
30/11/2018	-3	-3.6	-4	-3.1	-0.1	4.1	-2.1	109.7	-4.5	0
31/10/2018	0.4	2.1	-0.9	1.1	-1	6.5	-1.9	108.9	-4.7	-1
30/09/2018	0.1	-1.8	-0.1	6.6	-1.5	2.2	-5.5	110.4	-4.6	-1
31/08/2018	-3.9	-3.3	-3.5	-2.4	-6.2	4.4	29.8	111.4	-5.2	2
31/07/2018	-0.3	-1.6	-2.4	11.9	-2.5	2.8	13.6	111.9	-5	1
30/06/2018	-0.1	-1.5	-2.9	8.8	0.8	3.1	10.9	112.2	-4.5	1
31/05/2018	-1.5	0.3	-4.6	6	-5.3	5.3	3.6	110.1	-2.9	0
30/04/2018	4.8	5.5	-2	14.4	8.8	2	14.6	108.9	-3.4	0
31/03/2018	2.8	-0.6	-2.5	3.5	18	5.2	7.5	110.7	-3.7	2
28/02/2018	1.5	2	2.2	9.4	-6	4.4	3.5	111.8	-3.4	3
31/01/2018	2	3.5	2.7	10.5	-6.5	5.5	-8	112	-4.9	3
31/12/2017	-0.6	-2.1	1.4	6.2	-5.3	5.8	-3.4	112.8	-3.6	4
30/11/2017	3	4.4	2.2	8.7	-2.2	4.8	4.3	113.1	-1.6	3
31/10/2017	4.6	4.7	5.6	10.9	-2.4	2.6	10.6	112.7	-2.5	4
30/09/2017	3.2	1.5	2	6.1	6.4	4.4	6.4	112	-4	2
31/08/2017	8.4	2.3	8.5	13.8	16.2	3.9	12.8	109.4	-4.8	1
31/07/2017	5.6	5.2	2.7	0.9	15.8	3.8	12.9	111.8	-2.6	1
30/06/2017	4	7.4	0.7	-0.1	7.6	4.4	6.1	110	-3.4	3
31/05/2017	6.3	10.2	4.9	4.2	3.7	5.9	14.4	111.1	-5.7	1
30/04/2017	-2.3	-0.4	-0.8	-5.8	-5.7	4.4	8.8	108.9	-7.4	3
31/03/2017	6	11.8	2.2	2.6	6	4.6	2.1	108.5	-8.1	1
28/02/2017	0.3	1.8	0.5	-5.3	1.7	1.9	11.3	108.3	-9.9	2
31/01/2017	4.1	1.9	3.4	4.8	8.1	2.9	20.3	107.6	-10.1	2
31/12/2016	5.1	1.7	-0.4	2.9	21.7	3.4	29.3	107.3	-8.2	1
30/11/2016	3.2	1.9	0.4	-2.1	16.7	4.9	23.6	106.7	-9.9	1
31/10/2016	-3	0.2	-3.6	-5.1	-6.1	2.3	10.6	106.2	-12	1
30/09/2016	1.7	1.6	0.4	-2.7	8.7	2.8	15.5	104.5	-13.5	-2
31/08/2016	4.3	3.6	-1.3	-1.2	18.7	3	18.5	104	-14.1	-3
31/07/2016	-0.7	-5.3	-0.8	-3.1	12.1	3.8	4.4	104.2	-13.5	-2
30/06/2016	2	-1.7	1	1.9	12.5	3.3	15.9	104.5	-13.5	0
31/05/2016	0.7	-1.2	-0.2	-1.8	8.8	0.3	17.3	103.2	-13.1	-1
30/04/2016	3.8	-2.1	1.4	1.1	24.7	1.8	17.1	105.5	-12.5	-2
31/03/2016	2.8	-0.2	3.6	2.8	6.7	2.1	28.1	102.5	-13.6	-2
29/02/2016	5	2.7	3.2	7	10.6	3.9	26.9	103.4	-15.3	0
31/01/2016	5.5	4.6	1.3	-2	20.7	1.1	22.8	104.8	-10.4	1
31/12/2015	3.1	3.4	7.2	3.6	-2.7	1.2	18	103.1	-12.5	-2
30/11/2015	1.9	0.6	7.9	3.1	-6.7	1.5	25.1	104.1	-14.5	-2
31/10/2015	5	0.4	5.7	1.3	16.6	3.6	20.9	104.8	-12.7	-1
30/09/2015	5.2	7.9	2.7	-1.8	12.8	2.3	32.6	104.1	-14.3	-2
31/08/2015	3	2.5	-1	3.2	8.3	1.8	27.9	103.9	-15	-3
31/07/2015	4.5	4.9	2.5	0	12.8	2.5	15.4	106.1	-15.7	0
30/06/2015	4.1	1	3.9	2.3	13	3.5	37.1	106	-14.6	0
31/05/2015	2.2	-3.1	3	3	12.3	2.2	34.8	106.1	-14.4	1
30/04/2015	1.3	-0.3	1.9	1.2	3.5	4.1	26.7	106.7	-13.8	0

## ANEXOS- Dados Económicos

	IPI - Total excl. Construção - t.v.h. - Portugal	IPI - Bens de consumo - t.v.h. - Portugal	IPI - Bens intermédios - t.v.h. - Portugal	IPI - Bens de investimento - t.v.h. - Portugal	IPI - Energia - t.v.h. - Portugal	IVNCR (Índice Global) - Volume - t.v.h. - Portugal	Matrículas de veículos - passageiros - t.v.h. - Portugal	Indicador de sentimento económico - Portugal	Indicador de confiança dos consumidores - Portugal	Indicador de confiança na indústria - Portugal
	(%)	(%)	(%)	(%)	(%)	(%)	(%)	Índice	(%)	(%)
31/03/2015	1.8	0.3	5	2	-1	2.2	52.4	103.2	-13.9	-1
28/02/2015	-2.7	-5.6	2	-2.4	-4.4	2.3	39.7	101.7	-15.3	-2
31/01/2015	-5.1	-5.9	1	1.9	-17.1	2.2	31.8	102.6	-13.6	-3
31/12/2014	-1.6	-4.2	-1.8	-4.3	2.4	3.6	40.2	102.3	-17.4	-3
30/11/2014	-0.9	-2.5	-2.9	0.1	4.2	-1.4	37.1	101.5	-17.9	-3
31/10/2014	0.8	-1.6	-0.5	3.5	7.8	0.9	37.9	102.9	-16.4	-4
30/09/2014	-0.9	-5.7	-0.5	6.8	2	1.9	38.9	100.9	-21.6	-4
31/08/2014	2	6.8	-0.6	2.2	-2.5	0.7	30.6	99.8	-25.7	-5
31/07/2014	5.1	4.5	5.1	5.5	4.7	0.5	37.3	101.8	-22.7	-5
30/06/2014	2.1	6.3	1.5	1.8	-5.2	-0.6	29.8	101.5	-25.2	-5
31/05/2014	1.1	4.8	0.4	1.9	-5.2	0.4	42.3	101.3	-23.9	-4
30/04/2014	2.3	10.5	5.5	8.7	-19.1	-0.9	57.9	99.8	-25.7	-4
31/03/2014	-1.9	0	0.6	5.6	-13.1	0.1	50.4	100	-25.8	-4
28/02/2014	5.2	1	5.9	10.7	10	1.2	44.5	97.2	-28.1	-6
31/01/2014	4.8	0.9	4	3.5	16.4	1.1	37.5	98.6	-27.8	-5
31/12/2013	4.1	3.5	3.6	8.3	7.6	0.4	40.1	97.4	-28.9	-5
30/11/2013	3.4	3.4	3.1	2.8	7.1	3.9	25.2	93.6	-31.7	-8
31/10/2013	2.6	5	-1.4	-1.4	11.2	0.5	25.9	91.2	-33.4	-11
30/09/2013	0.1	2.1	0	-2	-0.2	-1.3	20.6	88.9	-37.3	-11
31/08/2013	-3.9	-4.5	-1.4	-7.5	-3.5	-0.7	14.8	87.4	-39.1	-12
31/07/2013	-3.8	0.9	-4.9	-0.6	-9.7	-1	18.6	83.9	-42.6	-15
30/06/2013	-1.2	-2	1.7	-3.8	2.3	-2.8	15	84.1	-41.9	-14
31/05/2013	0.2	1.4	-2.3	-2.1	10.8	-2.9	-5.2	82.9	-43.4	-13
30/04/2013	4.6	3.5	-2.4	-6.5	34.8	-1	-4.1	80.9	-41.5	-16
31/03/2013	1.1	-0.3	-9.7	-11.4	42.1	-4.7	-3.5	81	-43.3	-15
28/02/2013	-1.4	7.9	-11.1	-12.8	9.4	-6.8	3.9	79.8	-41.3	-17
31/01/2013	-0.7	6.7	-6.5	-9.6	5.3	-4.1	-4.4	77.4	-43.4	-17
31/12/2012	-4.3	0.7	-4.4	-8.9	-7.4	-7.9	-42.5	79.7	-43.2	-16
30/11/2012	-4.5	-0.6	-7.1	-5.3	-4.7	-4.8	-24.8	74.8	-44.5	-21
31/10/2012	-4.4	4	-4.8	-3.6	-19.3	-4.8	-19.6	74.1	-46.3	-20
30/09/2012	-5.3	0.7	-5.1	-4.7	-17.6	-5.1	-33.4	75.9	-46.1	-21
31/08/2012	-3.3	1.1	-0.3	-6.9	-10.4	-6.6	-35	81.3	-39	-17
31/07/2012	-3.4	-4.1	-0.6	-7.1	-6.8	-7.3	-36.4	78	-38.8	-20
30/06/2012	-4.1	-0.3	-4.7	-6.5	-11.1	-5.2	-37	79.6	-37.1	-17
31/05/2012	-6.2	-1.4	-2.3	-6.7	-25.3	-3.8	-28.5	78.9	-38.6	-19
30/04/2012	-11.4	-9.7	-10.2	-6.5	-21.6	-8.8	-42.9	80.1	-40.5	-16
31/03/2012	-9.4	-2.2	-2.2	-3.5	-35.4	-4.4	-47.8	78.8	-39.5	-18
29/02/2012	-6.7	-7.4	-4.6	-5.2	-10.1	-5.3	-46.2	77.2	-41.1	-19
31/01/2012	-6.2	-6.9	-3.1	-5.9	-12.7	-5.1	-42.7	77.2	-42.1	-18
31/12/2011	-9.2	-8.2	-4.9	-6.8	-19.5	-9.7	-57.1	75.8	-43.8	-19
30/11/2011	-4.9	-6	-3.6	-4.1	-6.3	-9	-46	75.9	-42.9	-19
31/10/2011	-3.4	-11.6	0.2	-2	6.1	-11.2	-38.2	82.4	-41.6	-15
30/09/2011	-2.1	-4.4	-4.1	-2.4	6.6	-9.6	-30.1	77.6	-44.8	-21
31/08/2011	0.4	2.4	-1.7	-3.8	2.7	-5.8	-27.7	83.4	-38.7	-16
31/07/2011	-1.8	-1.5	-0.7	-1.6	-4.7	-7	-27.2	88.1	-37.1	-8



## ANEXOS- Dados Económicos

	IPI - Total excl. Construção - t.v.h. - Portugal	IPI - Bens de consumo - t.v.h. - Portugal	IPI - Bens intermédios - t.v.h. - Portugal	IPI - Bens de investimento - t.v.h. - Portugal	IPI - Energia - t.v.h. - Portugal	IVNCR (Índice Global) - Volume - t.v.h. - Portugal	Matrículas de veículos - passageiros - t.v.h. - Portugal	Indicador de sentimento económico - Portugal	Indicador de confiança dos consumidores - Portugal	Indicador de confiança na indústria - Portugal
	(%)	(%)	(%)	(%)	(%)	(%)	(%)	Índice	(%)	(%)
30/06/2011	-2.9	-4.3	-2.8	-2.1	-1.9	-7.2	-32.8	88.7	-34.9	-12
31/05/2011	0.2	-1.7	1	-2.4	4.8	-9.2	-20.9	89.5	-36.8	-10
30/04/2011	2.4	2.9	4.1	-1.9	1.8	-7.7	-8.4	92.1	-39.8	-6
31/03/2011	2.8	-3.4	7.1	-4.3	12.6	-7.1	-17.8	92.9	-34.1	-9
28/02/2011	1.8	1.1	8.8	-1.2	-6.4	-5	-9.7	99.1	-32.3	-4
31/01/2011	-0.4	-0.5	5	-1	-7.6	-8.8	-6.8	94.9	-35.9	-5
31/12/2010	1	-5.1	3.4	-3.1	8.1		59.6	95	-35.2	-6
30/11/2010	-0.4	-5.3	2	-5.4	7.4		18.7	92.5	-38.8	-7
31/10/2010	-3.6	-3.5	-0.3	-8	-8		2.9	94.2	-37.3	-8
30/09/2010	-1.8	-4.3	6.8	-10.4	-5.8		17.6	96.8	-26.2	-7
31/08/2010	5.6	2.8	9.6	11	0.8		15.8	94	-26	-9
31/07/2010	-0.5	-4.1	1.2	-3.6	5.6		19.7	98.2	-25.9	-9
30/06/2010	4.8	2.5	8.5	-0.4	7.1		63.4	95	-23.4	-11

Tabela A-15: Informações sobre índice industrial e confiança

CF - Patrimónios anuais consolidados - Ativos financeiros - Total	
Descrição	Contas Nacionais Financeiras - Patrimónios anuais consolidados - Ativos financeiros - Total
Informação de referência	
Potenciação	10^6
Fonte	Banco de Portugal
Unidade de medida	Euros
Periodicidade	Annual
Natureza	Stock
Método de conversão para periodicidade superior	Último valor
Notas	
O Total da Economia engloba os sectores institucionais residentes: Sociedades Não Financeiras, Sociedades Financeiras, Administrações Públicas e Particulares.	
O sector das Sociedades Não Financeiras engloba as unidades institucionais que são produtores mercantis e cuja actividade principal é a produção de bens e serviços não financeiros.	
O sector das Sociedades Financeiras é composto por quatro subsectores: o Banco Central, as Outras Instituições Financeiras Monetárias, os Outros Intermediários Financeiros e Auxiliares Financeiros e as Sociedades de Seguros e Fundos de Pensões.	
No caso português, o sector das Administrações Públicas inclui os subsectores da Administração Central, da Administração Regional e Local e dos Fundos de Segurança Social.	

## ANEXOS- Dados Económicos

O sector dos Particulares engloba os indivíduos (cuja função principal é consumir), os empregadores e os trabalhadores por conta própria e as instituições privadas sem fins lucrativos

*Tabela A-16: Informação sobre dados da Tabela A-17*

	CF - Patrimónios anuais consolidados - Ativos financeiros - Total				
	Total Economia	Sociedades Não Financeiras	Sociedades Financeiras	Administrações Públicas	Particulares
	10^6 EUR	10^6 EUR	10^6 EUR	10^6 EUR	10^6 EUR
31/12/2018	344681	202510	614081	73272	401985
31/12/2017	342867	198365	611802	75594	395710
31/12/2016	331811	187724	593194	79551	377401
31/12/2015	324192	179445	585724	73123	373115
31/12/2014	324741	168731	594125	75372	366270
31/12/2013	308594	166434	592766	73601	359898
31/12/2012	318370	166609	620853	81482	352454
31/12/2011	317679	154795	626856	73500	356212
31/12/2010	348237	165858	685331	59510	360404

*Tabela A-17: Informações sobre patrimónios anuais consolidados*

IPC - Índice de Preços no Consumidor - Portugal	
Informação de referência	
Fonte	Instituto Nacional de Estatística
Unidade de medida	Índice
Periodicidade	Mensal
Método de cálculo	Valores Brutos
Método de conversão para periodicidade superior	Média

*Tabela A-18: Informação sobre dados da Tabela A-20*

(1)	Global
(2)	Produtos Alimentares e Bebidas não Alcoólicas
(3)	Bebidas Alcoólicas e Tabaco
(4)	Vestuário e Calçado
(5)	Habitação, Água, Electricidade, Gás e Outros Combustíveis
(6)	Acessórios para o lar, Equipamento Doméstico e Manutenção Corrente da Habitação
(7)	Saúde
(8)	Transportes
(9)	Comunicações

# ANEXOS- Dados Económicos

(10)	Lazer, Recreação e Cultura
(11)	Educação
(12)	Restaurantes e Hotéis
(13)	Bens e Serviços Diversos

Tabela A-19: Legenda sobre dados da Tabela A-26

IPC - Índice de Preços no Consumidor													
	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)	(12)	(13)
31/12/2018	103.66	104.45	121.09	89.98	108.75	99.44	103.88	100.82	112.41	99.79	106.41	109.55	102.59
30/11/2018	103.90	104.52	121.44	92.25	108.84	99.69	103.89	100.86	112.16	99.10	106.39	110.37	102.51
31/10/2018	104.37	104.22	121.26	92.14	108.65	99.28	103.82	102.30	112.20	99.52	106.28	114.42	102.40
30/09/2018	104.46	104.90	120.60	90.18	108.39	98.83	103.80	102.09	112.05	100.43	105.19	117.50	101.63
31/08/2018	103.30	104.86	120.62	75.90	108.19	99.11	103.62	102.95	112.25	102.21	105.15	114.63	101.33
31/07/2018	103.66	104.92	120.88	80.39	108.04	99.07	103.59	102.28	112.24	101.16	105.14	116.78	101.37
30/06/2018	104.29	104.53	120.85	92.45	107.91	99.41	103.48	101.43	112.66	101.03	105.09	115.13	101.45
31/05/2018	104.23	104.67	120.74	93.67	107.76	99.17	103.35	100.68	112.84	100.58	105.08	115.26	101.33
30/04/2018	103.80	104.47	119.74	93.64	107.47	99.52	103.34	100.14	112.78	100.77	105.09	111.99	101.38
31/03/2018	103.12	103.42	118.98	92.47	107.43	99.86	103.22	99.03	112.42	101.11	105.11	109.93	101.13
28/02/2018	101.23	103.46	116.85	73.90	107.39	99.49	103.08	98.66	112.51	100.74	105.11	107.82	100.93
31/01/2018	101.93	104.60	118.99	77.35	107.28	99.14	102.81	99.76	112.41	100.58	105.11	107.47	101.19
31/12/2017	102.97	104.13	118.01	93.67	106.13	99.43	102.90	99.38	111.93	99.91	105.12	107.96	101.37
30/11/2017	103.02	104.24	118.81	95.74	105.97	99.77	102.85	97.82	112.05	99.87	105.11	108.95	101.37
31/10/2017	103.38	103.91	117.54	95.66	105.81	99.48	102.81	97.58	112.06	100.04	105.06	115.15	101.47
30/09/2017	103.02	104.03	118.07	93.54	105.58	99.17	102.58	97.58	112.02	100.09	103.87	113.75	101.06
31/08/2017	102.06	103.93	117.79	77.81	105.40	99.42	102.37	98.99	111.78	101.70	103.84	113.38	100.84
31/07/2017	102.05	103.68	117.51	82.72	105.30	99.55	102.37	98.37	111.73	101.16	103.85	111.42	100.71
30/06/2017	102.73	103.25	117.46	95.05	105.47	99.66	102.13	97.47	111.64	101.05	103.84	110.90	100.89
31/05/2017	103.15	103.94	118.05	96.84	105.63	100.02	102.16	97.00	112.35	101.29	103.86	112.04	101.07
30/04/2017	103.39	103.52	117.11	97.21	105.82	99.96	102.34	99.38	112.31	101.39	103.85	111.90	100.33
31/03/2017	102.42	103.11	117.51	96.75	105.90	99.92	102.12	97.18	111.87	100.35	103.85	107.23	100.15
28/02/2017	100.65	102.99	116.03	75.74	105.64	100.43	102.06	97.66	111.64	100.81	103.84	105.32	99.98
31/01/2017	100.89	103.11	116.30	81.14	105.71	100.16	102.06	96.63	111.75	100.77	103.84	104.86	99.99
31/12/2016	101.49	101.81	115.65	96.99	104.76	99.69	101.85	95.72	111.80	99.78	103.83	104.79	100.24
30/11/2016	101.45	101.77	115.77	99.34	104.65	100.17	102.00	94.46	110.43	99.71	103.83	105.00	100.18
31/10/2016	101.96	102.56	115.38	99.34	104.58	99.92	101.97	95.11	109.38	100.23	103.81	108.63	100.04
30/09/2016	101.61	102.88	115.07	96.88	104.20	99.62	101.86	95.10	108.66	98.58	102.98	108.87	99.81
31/08/2016	100.91	103.55	115.20	79.32	104.72	100.00	101.72	97.30	107.65	98.95	102.96	109.12	99.73
31/07/2016	101.14	103.36	114.92	84.81	104.76	100.34	101.75	97.31	107.75	98.65	102.97	107.47	99.85
30/06/2016	101.81	103.03	114.92	96.64	105.70	100.21	101.67	96.01	107.79	98.94	102.98	107.13	100.09
31/05/2016	101.67	101.83	114.58	98.58	105.57	100.24	101.67	95.95	108.80	99.16	102.98	106.80	99.93
30/04/2016	101.39	101.51	113.37	99.21	105.66	100.48	101.60	95.02	108.97	98.73	102.98	105.86	99.92
31/03/2016	101.03	100.42	113.29	98.44	105.57	100.76	102.39	94.27	109.22	99.36	102.97	105.10	99.87
29/02/2016	99.11	100.60	113.13	77.16	105.53	100.63	102.33	92.22	109.54	99.99	102.97	103.36	99.55
31/01/2016	99.56	101.76	113.57	81.70	105.19	100.35	102.53	91.70	109.06	99.40	102.96	103.20	100.12
31/12/2015	100.60	101.18	113.08	97.91	104.12	100.05	102.72	93.95	106.29	98.88	102.98	102.89	99.82
30/11/2015	100.87	101.27	113.45	100.71	104.35	100.12	102.63	93.82	106.11	98.52	103.00	103.18	100.19
31/10/2015	101.07	102.10	112.87	100.80	104.33	99.90	102.58	94.22	106.14	97.73	103.01	104.25	99.93
30/09/2015	100.98	101.87	113.20	97.67	104.25	99.88	102.47	95.37	106.00	97.84	102.07	105.31	99.43
31/08/2015	100.19	101.71	112.77	78.70	104.43	99.97	102.50	98.58	105.99	99.24	102.05	105.65	99.32
31/07/2015	100.52	101.69	112.92	83.70	104.64	99.99	102.49	99.40	106.00	98.30	102.05	104.72	99.23
30/06/2015	101.26	101.99	112.78	97.47	104.97	99.59	102.60	97.46	105.93	98.02	102.02	104.40	99.35
31/05/2015	101.34	101.93	112.03	99.33	104.89	99.58	102.68	97.20	105.87	98.24	102.02	104.50	99.43
30/04/2015	100.91	101.42	110.70	99.17	104.94	99.59	102.54	95.92	105.85	98.00	102.02	103.79	99.48

## ANEXOS- Dados Económicos

	IPC - Índice de Preços no Consumidor												
	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)	(12)	(13)
31/03/2015	100.58	101.15	108.53	98.43	104.92	99.54	102.55	95.64	105.72	98.13	102.02	103.27	98.97
28/02/2015	98.72	101.23	108.71	77.34	104.91	99.50	102.53	93.42	105.37	98.12	102.03	103.20	98.48
31/01/2015	98.79	101.54	108.81	81.57	105.27	99.59	102.55	91.66	103.56	98.44	102.03	102.58	98.54
31/12/2014	100.21	101.19	108.40	100.19	104.08	99.99	102.43	94.03	101.30	98.67	102.03	102.65	98.51
30/11/2014	100.22	100.91	108.76	102.43	104.52	100.14	102.45	93.49	101.32	97.73	102.03	102.66	98.52
31/10/2014	100.43	100.82	108.63	101.72	104.67	99.99	102.39	95.03	101.31	98.26	102.06	103.27	98.36
30/09/2014	100.10	99.89	108.56	97.89	104.48	98.71	102.18	96.44	100.45	98.38	101.47	104.23	98.42
31/08/2014	99.53	99.99	108.05	80.84	104.38	98.84	102.02	100.42	100.98	99.66	101.46	104.07	98.27
31/07/2014	99.76	100.15	107.58	86.16	104.39	98.85	102.14	99.82	100.97	98.78	101.45	103.24	98.82
30/06/2014	100.45	100.05	107.51	100.95	104.33	98.82	102.10	97.65	100.99	98.54	101.50	102.82	99.33
31/05/2014	100.38	99.86	106.63	101.92	104.38	98.98	102.10	96.21	102.21	99.05	101.51	102.89	99.45
30/04/2014	100.51	100.24	106.40	101.65	104.42	98.96	102.03	97.28	102.22	99.39	101.52	101.87	99.51
31/03/2014	100.27	100.87	105.78	100.43	104.58	98.79	101.95	95.89	102.02	99.05	101.47	101.27	99.58
28/02/2014	98.92	101.22	105.35	78.79	104.70	98.67	101.87	96.09	102.50	99.64	101.42	101.40	99.32
31/01/2014	99.18	101.67	105.56	82.80	104.18	98.61	102.20	95.69	102.35	99.75	101.42	101.23	99.09
31/12/2013	100.56	101.57	105.15	102.07	102.13	98.89	102.10	98.34	101.03	99.91	101.43	100.99	98.99
30/11/2013	100.20	101.44	105.46	104.13	102.08	99.00	101.98	95.24	101.05	99.44	101.45	101.20	98.94
31/10/2013	100.43	101.46	105.30	104.00	101.99	99.28	101.99	96.37	100.62	99.71	101.48	101.61	99.05
30/09/2013	100.47	102.13	104.68	98.86	102.09	99.31	101.36	97.50	100.59	100.80	101.09	102.25	99.05
31/08/2013	99.89	103.27	104.52	81.39	102.15	99.18	101.30	99.84	100.59	100.65	101.09	102.75	98.51
31/07/2013	100.64	103.31	104.33	93.10	102.19	99.62	101.31	99.74	100.60	100.74	101.09	102.38	98.60
30/06/2013	100.87	102.65	104.49	102.43	101.96	99.82	101.35	97.50	100.62	100.35	101.09	102.19	99.96
31/05/2013	100.82	102.24	104.40	103.63	102.18	99.81	101.80	96.71	100.62	100.23	101.10	102.22	100.17
30/04/2013	100.65	101.18	103.94	103.54	102.28	99.87	101.86	97.02	100.61	100.73	101.06	101.73	100.21
31/03/2013	100.64	101.29	103.49	101.46	102.43	99.70	101.16	98.94	100.05	100.55	101.07	101.10	100.01
28/02/2013	99.00	101.27	101.58	80.61	102.37	99.66	100.85	97.94	100.05	100.59	101.06	100.77	99.70
31/01/2013	99.12	101.47	101.24	85.03	101.99	99.79	100.82	97.02	98.99	101.17	101.12	100.62	99.52
31/12/2012	100.37	100.96	100.84	104.85	101.17	99.99	99.13	98.87	99.49	100.95	101.11	100.44	99.80
30/11/2012	100.36	100.91	100.94	107.44	100.93	99.95	99.01	98.67	99.48	100.11	101.12	100.49	99.92
31/10/2012	100.67	100.98	101.11	107.00	100.89	100.04	98.84	100.45	99.49	100.20	101.08	100.50	100.03
30/09/2012	100.36	100.22	101.14	101.00	100.64	99.85	97.90	101.23	99.74	100.87	99.65	100.68	100.07
31/08/2012	99.74	100.32	101.18	83.78	100.30	99.91	97.90	101.63	99.81	101.29	99.62	100.70	99.99
31/07/2012	99.88	100.83	101.67	94.25	100.20	99.94	98.39	99.69	99.81	100.65	99.61	100.49	99.86
30/06/2012	99.89	99.81	100.49	106.04	99.76	99.95	98.81	99.00	100.09	99.52	99.61	100.02	100.07
31/05/2012	100.11	99.17	100.32	107.45	99.77	100.22	99.76	100.13	100.11	99.35	99.61	99.92	100.18
30/04/2012	100.47	99.17	100.20	107.44	99.62	100.08	101.72	101.46	100.46	99.30	99.62	99.79	100.14
31/03/2012	100.18	99.15	99.07	106.28	99.34	99.95	102.01	100.92	100.63	98.97	99.63	99.30	100.03
29/02/2012	99.03	99.29	96.64	84.79	98.93	99.92	102.58	99.54	100.46	99.68	99.66	99.18	100.04
31/01/2012	98.95	99.20	96.42	89.68	98.44	100.20	103.95	98.42	100.45	99.11	99.68	98.50	99.89
31/12/2011	98.48	97.82	96.24	110.18	96.34	100.44	100.92	97.24	98.72	99.15	99.70	96.09	99.44
30/11/2011	98.50	97.69	96.20	113.79	96.30	100.61	101.03	97.08	98.80	98.10	99.69	95.96	99.26
31/10/2011	98.57	97.87	96.13	113.58	96.20	100.66	101.10	97.26	98.80	98.37	99.75	95.93	99.43
30/09/2011	97.55	97.37	96.19	109.02	90.80	100.60	99.69	97.54	99.08	98.73	98.20	96.01	99.14
31/08/2011	96.76	97.14	96.16	87.54	90.80	100.47	99.93	97.88	99.31	99.96	98.22	95.83	98.96
31/07/2011	97.19	96.92	96.11	99.21	90.80	100.75	100.46	97.64	99.34	99.77	98.12	95.73	99.01
30/06/2011	97.26	96.58	95.96	111.99	90.66	100.55	98.96	96.76	99.36	99.02	98.11	95.60	98.82
31/05/2011	97.48	96.61	95.64	113.66	90.67	100.45	99.09	97.48	100.18	99.39	98.09	95.48	98.78
30/04/2011	97.53	96.44	95.60	114.17	90.64	100.34	99.33	97.85	100.21	98.87	98.09	95.70	98.71
31/03/2011	97.13	96.34	94.86	113.03	90.50	100.29	98.59	96.39	100.32	99.10	98.08	95.67	98.76
28/02/2011	95.59	95.99	94.33	87.17	90.25	100.31	98.45	94.67	100.34	99.24	98.09	95.36	98.32
31/01/2011	95.59	96.01	92.28	93.03	89.84	100.23	98.20	94.18	100.10	99.52	98.09	95.30	98.21
31/12/2010	95.05	95.71	91.15	114.54	87.66	99.47	93.92	91.69	96.56	98.66	98.00	94.95	97.94
30/11/2010	94.77	95.72	90.34	115.55	87.11	99.39	95.77	89.73	96.73	98.29	97.99	94.98	97.90
31/10/2010	94.60	95.78	89.64	115.32	86.90	99.29	95.43	89.25	96.75	98.52	97.97	95.03	97.69
30/09/2010	94.20	95.63	89.62	110.91	86.71	99.19	94.21	89.31	96.76	98.88	96.15	94.82	97.18

## ANEXOS- Dados Económicos

	IPC - Índice de Preços no Consumidor												
	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)	(12)	(13)
31/08/2010	94.03	95.83	89.03	99.44	86.64	99.12	95.64	90.16	96.88	99.46	96.09	94.86	96.94
31/07/2010	94.22	95.29	88.28	106.60	86.66	99.11	96.01	90.38	96.90	98.92	96.03	94.73	96.94
30/06/2010	94.06	95.02	87.47	114.92	86.09	99.17	96.44	89.00	96.20	97.74	96.02	94.35	96.87
31/05/2010	93.88	94.26	87.37	116.00	86.06	99.14	95.72	89.02	96.36	97.67	96.03	94.25	96.71
30/04/2010	93.75	94.21	87.27	115.90	85.87	99.29	95.68	88.68	96.04	97.36	96.01	94.15	96.83
31/03/2010	93.37	93.81	87.21	114.70	85.62	99.41	95.45	87.72	95.82	97.47	96.07	93.74	96.82
28/02/2010	92.30	93.76	87.10	95.21	85.05	99.54	95.28	86.40	97.30	97.51	96.07	93.55	97.01
31/01/2010	92.27	93.89	86.93	99.06	84.51	99.68	95.17	85.73	97.57	97.36	96.04	93.31	97.11

*Tabela A-20: Informações sobre índice de preços no consumidor*

Empréstimos concedidos a famílias - consumo e outros fins	
Descrição	Total dos empréstimos concedidos pelo setor financeiro a famílias, com finalidade consumo e outros fins
Informação de referência	
Potenciação	10^6
Fonte	Banco de Portugal
Unidade de medida	Euros
Periodicidade	Trimestral
Natureza	Posições em fim de período
Método de Cálculo	Valores Nominais
Método de conversão para periodicidade superior	Último Valor

*Tabela A-21: Informação sobre dados da Tabela A-26*

Crédito vencido dos empréstimos a famílias - consumo e outros fins	
Descrição	Crédito vencido dos empréstimos concedidos pelo setor financeiro a famílias, com finalidade consumo e outros fins
Informação de referência	
Potenciação	10^6
Fonte	Banco de Portugal
Unidade de medida	Euros
Periodicidade	Trimestral
Natureza	Posições em fim de período
Método de Cálculo	Valores Nominais
Método de conversão para periodicidade superior	Último Valor

*Tabela A-22: Informação sobre dados da Tabela A-26*

Rácio de crédito vencido das famílias - consumo e outros fins	
Descrição	Rácio de crédito vencido dos empréstimos concedidos pelo setor financeiro a famílias com finalidade consumo e outros fins

## ANEXOS- Dados Económicos

Informação de referência	
Fonte	Banco de Portugal
Unidade de medida	Percentagem
Periodicidade	Trimestral
Natureza	N/A
Método de conversão para periodicidade superior	Último Valor

*Tabela A-23: Informação sobre dados da Tabela A-26*

Nº devedores do setor famílias - consumo e outros fins	
Descrição	Número de devedores dos empréstimos concedidos pelo setor financeiro ao setor das famílias com finalidade consumo e outros fins
Informação de referência	
Potenciação	10 <sup>3</sup>
Fonte	Banco de Portugal
Unidade de medida	Número de Pessoas
Periodicidade	Trimestral
Natureza	N/A
Método de conversão para periodicidade superior	Último Valor

*Tabela A-24: Informação sobre dados da Tabela A-26*

% de devedores com crédito vencido do setor famílias - consumo e outros fins	
Descrição	Percentagem de devedores com crédito vencido dos empréstimos concedidos pelo setor financeiro a famílias, com finalidade consumo e outros fins
Informação de referência	
Fonte	Banco de Portugal
Unidade de medida	Percentagem
Periodicidade	Trimestral
Natureza	N/A
Método de conversão para periodicidade superior	Último Valor

*Tabela A-25: Informação sobre dados da Tabela A-26*

	Empréstimos concedidos a famílias - consumo e outros fins	Crédito vencido dos empréstimos a famílias - consumo e outros fins	Rácio de crédito vencido das famílias - consumo e outros fins	Nº devedores do setor famílias - consumo e outros fins	% de devedores com crédito vencido do setor famílias - consumo e outros fins
	10 <sup>6</sup> EUR	10 <sup>6</sup> EUR	(%)	10 <sup>3</sup> NPS	(%)
30/06/2019	26671	1881	7.1	3714.6	10.9
31/03/2019	26363	1952	7.4	3694.4	11.2
31/12/2018	26120	1982	7.6	3696.4	10.8
30/09/2018	26021	2232	8.6	3671.7	11.9
30/06/2018	25777	2205	8.6	3657.2	11.7
31/03/2018	25412	2326	9.2	3663.2	12.6

## ANEXOS- Dados Económicos

31/12/2017	25144	2364	9.4	3661.4	12.7
30/09/2017	24813	2599	10.5	3618.2	13.7
30/06/2017	24517	2744	11.2	3590.9	14.1
31/03/2017	24244	2881	11.9	3584.3	14.5
31/12/2016	24161	2935	12.1	3594.9	14.3
30/09/2016	23787	3278	13.8	3553.1	15.3
30/06/2016	23521	3269	13.9	3544.9	15.5
31/03/2016	23406	3241	13.8	3551.3	15.6
31/12/2015	23787	3331	14	3574.4	15.4
30/09/2015	23728	3499	14.7	3531	16.2
30/06/2015	23747	3528	14.9	3541.2	16.7
31/03/2015	23833	3503	14.7	3563.5	16.8
31/12/2014	24030	3458	14.4	3594.1	16.4
30/09/2014	24204	3423	14.1	3581.4	16.7
30/06/2014	24421	3334	13.7	3578.1	16.9
31/03/2014	24695	3346	13.5	3597.1	17.1
31/12/2013	25135	3293	13.1	3624.7	16.6
30/09/2013	25601	3281	12.8	3597	16.7
30/06/2013	26172	3293	12.6	3616.6	17.4
31/03/2013	26736	3269	12.2	3633.1	17.4
31/12/2012	27438	3226	11.8	3669.6	16.9
30/09/2012	27948	3201	11.5	3687.1	17.2
30/06/2012	28987	3322	11.5	3711.2	17.5
31/03/2012	29822	3231	10.8	3740.7	17
31/12/2011	30682	3215	10.5	3770.9	16.2
30/09/2011	31753	3188	10	3798.9	16.2
30/06/2011	32177	2952	9.2	3802.5	15.9
31/03/2011	32699	2819	8.6	3820	15.7
31/12/2010	33350	2825	8.5	3822	15.2
30/09/2010	33650	2854	8.5	3805.9	15.1
30/06/2010	33715	2666	7.9	3783.2	15
31/03/2010	33786	2561	7.6	3784.3	14.7

Tabela A-26: Informações sobre empréstimo, créditos e dívidas

Tx juro (novas operações): empréstimos a particulares da UM, consumo	
Descrição	Taxas de juro sobre novas operações de empréstimos concedidos por outras instituições financeiras monetárias a particulares residentes na área do euro - Consumo - Total
Informação de referência	
Fonte	Banco de Portugal
Unidade de medida	Porcentagem
Periodicidade	Mensal
Natureza	Taxa de Juro
Método de cálculo	Média Ponderada
Método de conversão para periodicidade superior	Último valor
Notas	Operações denominadas em euros e excluindo os descobertos bancários.

## ANEXOS- Dados Económicos

Tabela A-27: Informação Tabela Tx Juro (novas operações). Empréstimos particulares. Consumo - Total.

Tx juro (novas operações): empréstimos a particulares da UM, consumo, até 1 ano	
Descrição	Taxas de juro sobre novas operações de empréstimos concedidos por outras instituições financeiras monetárias a particulares residentes na área do euro - Consumo - Com prazo de fixação inicial de taxa até 1 ano
Informação de referência	
Fonte	Banco de Portugal
Unidade de medida	Percentagem
Periodicidade	Mensal
Natureza	Taxa de Juro
Método de cálculo	Média Ponderada
Método de conversão para periodicidade superior	Último valor
Notas	Operações denominadas em euros e excluindo os descobertos bancários. (1) Inclui operações a taxa variável.

*Tabela A-28: Informação Tabela Tx Juro (novas operações). Empréstimos particulares. Consumo - até 1 ano.*

Tx juro (novas operações): empréstimos a particulares da UM, consumo, 1 a 5 anos	
Descrição	Taxas de juro sobre novas operações de empréstimos concedidos por outras instituições financeiras monetárias a particulares residentes na área do euro - Consumo - Com prazo de fixação inicial de taxa de 1 a 5 anos
Informação de referência	
Fonte	Banco de Portugal
Unidade de medida	Percentagem
Periodicidade	Mensal
Natureza	Taxa de Juro
Método de cálculo	Média Ponderada
Método de conversão para periodicidade superior	Último valor
Notas	Operações denominadas em euros e excluindo os descobertos bancários. (1) Inclui operações a taxa variável.

*Tabela A-29: Informação Tabela Tx Juro (novas operações). Empréstimos particulares. Consumo - de 1 a 5 anos.*

Tx juro (novas operações): empréstimos a particulares da UM, consumo - TAEG	
Descrição	Taxas de juro sobre novas operações de empréstimos concedidos por outras instituições financeiras monetárias a particulares residentes na área do euro - Consumo - Taxa anual de encargos efectiva global
Informação de referência	



## ANEXOS- Dados Económicos

Fonte	Banco de Portugal
Unidade de medida	Percentagem
Periodicidade	Mensal
Natureza	Taxa de Juro
Método de cálculo	Média Ponderada
Método de conversão para periodicidade superior	Último valor
Notas	Operações denominadas em euros e excluindo os descobertos bancários.

Tabela A-30: Informação Tabela Tx Juro (novas operações). Empréstimos particulares. Consumo - TAEG.

	Tx juro (novas operações): empréstimos a particulares da UM, consumo			
	Total	até 1 ano	1 a 5 anos	TAEG
	(%)	(%)	(%)	(%)
31/12/2018	6.77	5.13	6.19	8.63
30/11/2018	7.06	5.32	6.72	8.92
31/10/2018	7.22	5.59	6.72	9.06
30/09/2018	7.19	5.59	6.86	9.05
31/08/2018	7.04	5.49	6.61	8.91
31/07/2018	7.07	5.4	6.56	8.85
30/06/2018	7	5.27	6.61	8.9
31/05/2018	7.21	5.49	6.81	9.26
30/04/2018	7.13	5.56	6.95	9.05
31/03/2018	7.27	5.52	7.08	9.14
28/02/2018	7.48	5.67	7.48	9.41
31/01/2018	7.48	5.75	7.45	9.39
31/12/2017	6.88	5.18	7.03	8.75
30/11/2017	7.18	5.47	7.32	9.04
31/10/2017	7.23	5.55	7.22	9.16
30/09/2017	7.2	5.52	7.01	9.15
31/08/2017	7.44	5.72	7.53	9.28
31/07/2017	7.39	5.73	7.41	9.24
30/06/2017	7.28	5.6	7.27	9.07
31/05/2017	7.36	5.65	7.46	9.17
30/04/2017	7.4	5.6	7.52	9.19
31/03/2017	7.48	5.78	7.57	9.27
28/02/2017	7.58	5.79	7.64	9.36
31/01/2017	7.52	6.05	7.6	9.29
31/12/2016	7.14	5.63	7.39	8.8
30/11/2016	7.39	5.77	7.7	9.19
31/10/2016	7.47	5.95	7.64	9.42
30/09/2016	7.55	6.09	7.69	9.42
31/08/2016	7.43	5.73	7.89	9.33
31/07/2016	7.5	5.92	8.01	9.35
30/06/2016	7.45	5.9	8.16	9.15
31/05/2016	7.53	6.06	8.18	9.33
30/04/2016	7.57	6.16	8.06	9.29
31/03/2016	7.59	6.29	7.76	9.3
29/02/2016	7.66	6.15	7.59	9.49
31/01/2016	7.76	6.18	7.93	9.53
31/12/2015	7.7	6.15	8.13	9.27
30/11/2015	7.99	6.46	8.4	9.62
31/10/2015	8.05	6.52	8.62	9.69
30/09/2015	8.04	6.66	8.37	9.62

## ANEXOS- Dados Económicos

	Tx juro (novas operações): empréstimos a particulares da UM, consumo			
	Total	até 1 ano	1 a 5 anos	TAEG
	(%)	(%)	(%)	(%)
31/08/2015	8.1	6.54	8.61	9.66
31/07/2015	8.1	6.43	8.71	9.63
30/06/2015	8.13	6.45	8.64	9.79
31/05/2015	8.21	6.55	8.85	9.79
30/04/2015	8.28	6.4	9.17	9.91
31/03/2015	8.44	6.26	9.56	10.01
28/02/2015	8.88	7.46	9.73	10.62
31/01/2015	8.68	7.33	9.36	10.43
31/12/2014	8.61	7.33	9.67	10.18
30/11/2014	8.71	7.47	9.76	10.37
31/10/2014	8.64	7.39	9.51	10.36
30/09/2014	9.04	7.81	10.04	10.73
31/08/2014	9	7.83	10.06	10.82
31/07/2014	8.85	7.41	10.22	10.59
30/06/2014	9.18	8.02	10.78	10.91
31/05/2014	9.2	7.93	10.79	10.85
30/04/2014	9.26	7.96	10.58	10.96
31/03/2014	9.39	7.91	10.79	10.95
28/02/2014	9.61	8.15	11.13	11.23
31/01/2014	9.61	8.09	11.25	11.26
31/12/2013	9.53	8.3	11.02	11.09
30/11/2013	9.47	8.37	10.54	11.17
31/10/2013	9.68	8.47	11.17	11.29
30/09/2013	10.02	8.77	11.65	11.64
31/08/2013	9.95	8.63	11.57	11.54
31/07/2013	9.81	8.49	11.38	11.5
30/06/2013	9.79	8.26	11.77	11.38
31/05/2013	9.81	8.25	11.74	11.3
30/04/2013	10.01	8.28	12.26	11.45
31/03/2013	10.14	8.33	12.52	11.63
28/02/2013	10.29	8.37	12.47	11.82
31/01/2013	10.22	8.43	12.42	11.84
31/12/2012	9.71	8.18	11.89	10.97
30/11/2012	9.94	8.27	11.93	11.35
31/10/2012	10.03	7.76	11.49	11.75
30/09/2012	10.48	7.91	11.95	12.22
31/08/2012	10.62	8.19	12.14	12.26
31/07/2012	10.43	8.1	12.07	12.09
30/06/2012	10.34	7.99	12.27	11.9
31/05/2012	10.57	8.13	12.41	12.22
30/04/2012	10.98	8.34	13.25	12.74
31/03/2012	10.62	8.03	12.74	12.26
29/02/2012	10.72	8.36	12.46	12.36
31/01/2012	10.56	8.41	12.2	12.32
31/12/2011	10.04	8.04	11.58	11.65
30/11/2011	10.36	8.1	12.08	12.07
31/10/2011	10.38	8.16	12.12	12.04
30/09/2011	10.45	8.28	11.78	11.99
31/08/2011	10.35	8.36	11.63	12.05
31/07/2011	10.03	7.94	11.46	11.71
30/06/2011	9.8	7.64	11.3	11.36
31/05/2011	9.79	7.54	11.34	11.31

	Tx juro (novas operações): empréstimos a particulares da UM, consumo			
	Total	até 1 ano	1 a 5 anos	TAEG
	(%)	(%)	(%)	(%)
30/04/2011	9.85	7.39	11.84	11.44
31/03/2011	9.84	7.53	11.48	11.41
28/02/2011	9.51	7.41	11.46	11.06
31/01/2011	9.18	7.23	10.75	10.57
31/12/2010	8.39	6.67	10.05	9.89
30/11/2010	8.96	6.99	11.03	10.37
31/10/2010	9.08	6.93	11.49	10.6
30/09/2010	9.1	6.67	11.1	10.79
31/08/2010	9.11	6.67	11.23	10.84
31/07/2010	8.87	6.24	11.54	10.52
30/06/2010	8.66	6.17	11.16	10.33

Tabela A-31: Informação sobre Taxas de Juro de empréstimos a particulares

### A.3 Resultados Experimentais

#### A.3.1 Redes Neurais (Net Console)

Para se entender as tabelas contidas nesta secção é necessário compreender o que cada coluna representa:

$x_0$  a  $x_{10}$ : São as respostas quantitativas do questionário feitas aos gestores ( $x_0$  para a questão 1,  $x_1$  para a questão 2, e assim sucessivamente). Ou seja, representam os valores de entrada para a rede neuronal que modela o ambiente calculado previamente.

$y$ : representa o valor real do rácio entre o resultado financeiro do ano considerado e do ano transato. Exemplo: um  $y$  de 1,10 indica que existiu um aumento no resultado financeiro de 10% entre os anos.

$Y'$ : representa o valor estimado (previsto) pelo modelo do ambiente previamente calculado ao aplicar os valores inerente às entradas ( $x_0$  a  $x_{10}$ ).

Erro: Representa a diferença (em valor absoluto) entre o valor real e o valor estimado pelo modelo, ou seja, entre  $y$  e  $y'$ .

Erro(%): Representa o valor do erro (valor absoluto) em modo relativo comparativamente ao valor real. Exemplo: um erro de 10% significa que  $y'=(1+0,1)*y$ , ou  $y'=(1-0,1)*y$ .

Cat: Representa a categoria do erro onde este se enquadra. Foram consideradas 7 categorias diferentes: [ $\varepsilon < 5\%$ ;  $5\% \leq \varepsilon < 10\%$ ;  $10\% \leq \varepsilon < 20\%$ ;  $20\% \leq \varepsilon < 30\%$ ;  $30\% \leq \varepsilon < 40\%$ ;  $40\% \leq \varepsilon < 50\%$ ;  $\varepsilon \geq 50\%$ ], nomeadamente representados por [ $<5\%$ ;  $<10\%$ ;  $<20\%$ ;  $<30\%$ ;  $<40\%$ ;  $<50\%$ ;  $\geq 50\%$ ].

#### Net Console: Modelo Estratégico 2013

$x_0$	$x_1$	$x_2$	$x_3$	$x_4$	$x_5$	$x_6$	$x_7$	$x_8$	$x_9$	$x_{10}$	$y$	$y'$	error	error(%)	Cat.
0	5	0	0	0	0	0	0	0	0	0	1.096658	0.853943	0.242715	22.13%	<30%
-5	7	0	6	5	6	-7	8	0	0	7	1.017635	0.703468	0.314167	30.87%	<40%
-5	0	9	0	0	0	0	5	0	0	0	0.848176	0.905048	0.056873	6.71%	<10%
0	0	0	0	0	0	0	0	0	5	8	0.951753	1.381085	0.429332	45.11%	<50%
7	5	3	0	0	8	-8	0	5	0	0	0.840433	1.000322	0.159889	19.02%	<20%
-2	-1	7	0	1	0	-4	3	3	1	7	0.996569	1.001281	0.004712	0.47%	<5%
1	3	0	7	0	1	0	0	2	0	0	1.164824	0.978943	0.185881	15.96%	<20%
0	0	0	2	1	0	3	2	2	0	3	0.998507	0.990287	0.008220	0.82%	<5%
0	0	2	0	1	1	5	2	5	7	9	0.961998	1.269507	0.307509	31.97%	<40%
2	5	0	3	5	-3	-3	0	2	0	2	1.096363	0.922440	0.173923	15.86%	<20%
0	3	0	2	0	-4	-3	4	3	0	7	1.601998	1.203517	0.398481	24.87%	<30%

# ANEXOS- Resultados Experimentais

x 0	x 1	x 2	x 3	x 4	x 5	x 6	x 7	x 8	x 9	x 10	y	y'	error	error(%)	Cat
0	9	0	6	0	-4	-7	7	9	0	0	1.188654	0.856947	0.331707	27.91%	<30%
-1	-2	2	5	7	-5	-4	5	6	5	7	1.211304	0.938000	0.273304	22.56%	<30%
-5	7	5	7	5	5	-4	0	0	0	2	1.240413	0.741682	0.498731	40.21%	<50%
-5	0	4	0	0	0	0	8	0	5	8	1.383015	0.960497	0.422518	30.55%	<40%
0	4	0	5	0	0	-2	0	0	0	5	0.965868	0.922090	0.043779	4.53%	<5%
1	4	2	0	0	8	2	8	8	0	8	0.816893	1.538308	0.721415	88.31%	>50%
-4	-2	2	4	2	-3	-5	5	4	0	4	1.103093	1.222176	0.119083	10.80%	<20%
-5	-5	9	0	0	2	-5	0	6	8	9	0.932702	0.857730	0.074972	8.04%	<10%
-9	9	5	5	0	0	0	0	0	0	6	1.892519	1.092816	0.799704	42.26%	<50%
-7	-5	0	3	0	-4	-3	0	4	3	0	1.086473	1.283779	0.197306	18.16%	<40%
2	2	0	3	0	3	-6	5	1	1	1	1.210128	0.964853	0.245275	20.27%	<30%
0	5	0	2	0	0	0	5	0	3	3	1.020727	1.261611	0.240884	23.60%	<30%
-5	0	0	5	7	-5	-5	0	5	0	0	0.892945	1.004224	0.111279	12.46%	<20%
1	2	0	2	2	-2	2	2	3	0	0	1.061803	0.991195	0.070608	6.65%	<10%
-6	-9	0	0	0	0	0	0	0	0	0	1.182270	1.748867	0.566598	47.92%	<50%
5	5	0	5	0	-5	-5	5	5	5	9	1.087892	0.983672	0.104220	9.58%	<10%
3	4	0	4	3	5	-4	3	5	5	3	1.110424	1.340561	0.230137	20.73%	<30%
6	5	0	0	0	7	0	7	0	6	0	0.777791	1.334086	0.556295	71.52%	>50%
-4	0	1	0	0	-5	-1	3	3	0	3	1.017774	1.115673	0.097899	9.62%	<10%
0	0	0	7	0	0	-6	7	7	0	0	1.029136	1.028067	0.001069	0.10%	<5%
-4	7	0	7	0	4	0	0	3	3	4	1.278000	1.054802	0.223198	17.46%	<20%
0	3	0	1	0	0	-1	0	2	0	0	0.964221	1.282098	0.317878	32.97%	<40%
0	4	0	0	0	2	0	0	0	0	0	1.377280	0.793548	0.583732	42.38%	<50%
0	6	0	6	6	-7	-4	3	5	1	6	1.258863	1.408022	0.149160	11.85%	<20%
0	0	7	0	0	-6	-6	5	3	0	7	1.082894	1.119191	0.036297	3.35%	<5%
4	8	0	5	9	-4	-5	4	5	0	5	0.772959	0.821600	0.048641	6.29%	<10%
-1	-1	0	0	0	-7	0	1	7	0	4	1.013652	1.283081	0.269429	26.58%	<30%

Tabela A-32: Resultados previsão através RNA (Net Console) Ano 2013

## Net Console: Modelo Estratégico 2014

x 0	x 1	x 2	x 3	x 4	x 5	x 6	x 7	x 8	x 9	x 10	y	y'	error	error(%)	Cat
-6	0	0	5	0	5	0	0	6	0	7	1.043067	0.794698	0.248369	23.81%	<30%
-2	-1	7	0	1	0	-4	4	3	1	7	0.844564	0.851097	0.006534	0.77%	<5%
-5	-1	5	4	2	-6	-4	3	2	4	6	0.562434	1.255797	0.693363	123.28%	>50%
1	4	0	3	0	0	0	3	6	0	0	1.133157	1.029246	0.103911	9.17%	<10%
0	4	0	2	0	-5	-4	0	0	2	3	0.965855	1.136203	0.170348	17.64%	<20%
-5	7	5	7	5	6	-5	3	0	4	5	0.987610	0.950168	0.037442	3.79%	<5%
-6	6	0	0	8	0	-2	4	0	0	3	0.917597	1.105792	0.188196	20.51%	<30%
5	4	0	0	0	0	-1	6	6	0	5	0.864773	0.880130	0.015356	1.78%	<5%
6	0	5	0	0	-5	-6	6	0	0	5	0.892680	1.104100	0.211420	23.68%	<30%
-7	-2	6	0	0	-4	0	0	6	7	9	0.757206	0.932706	0.175500	23.18%	<30%
-7	0	8	7	7	0	0	0	0	0	3	1.144752	1.147105	0.002353	0.21%	<5%
-3	0	0	2	7	3	-5	5	4	5	6	1.106980	1.231387	0.124407	11.24%	<20%
2	4	0	5	0	5	-5	5	1	4	2	1.485567	1.264281	0.221287	14.90%	<20%
0	7	2	6	0	-7	-6	5	5	0	0	1.072213	1.044341	0.027872	2.60%	<5%
0	0	0	4	0	0	0	0	2	0	5	1.090583	1.101811	0.011228	1.03%	<5%
3	1	0	4	0	-4	-3	4	3	0	0	1.191054	1.295072	0.104017	8.73%	<10%
0	0	0	2	0	-1	-3	4	2	0	1	1.234972	1.082811	0.152161	12.32%	<20%
1	2	0	4	3	-3	-6	4	4	5	0	1.107694	0.924310	0.183384	16.56%	<20%
-6	3	8	1	6	0	-2	1	3	7	7	0.977225	1.029011	0.051786	5.30%	<10%
0	0	0	0	5	0	0	0	5	6	9	1.037107	0.850247	0.186860	18.02%	<20%
-6	-3	0	0	0	0	0	0	0	0	0	1.320111	1.213207	0.106904	8.10%	<10%
0	0	0	7	0	0	-6	7	6	0	0	0.977081	0.877779	0.099302	10.16%	<20%
-6	0	5	7	0	0	-7	3	4	4	7	1.237124	1.159453	0.077671	6.28%	<10%
1	3	0	7	0	6	-5	4	6	2	5	1.108880	1.217010	0.108130	9.75%	<10%
-4	0	0	4	1	-3	-4	4	2	1	4	1.524711	1.119666	0.405045	26.57%	<30%
0	0	0	5	0	-6	-7	7	5	0	9	1.216466	1.252892	0.036426	2.99%	<5%
5	6	0	1	0	0	4	0	0	0	0	1.327686	1.927796	0.600109	45.20%	<50%
0	5	9	0	0	5	-5	5	0	5	0	1.005291	1.095197	0.089906	8.94%	<10%
4	5	0	5	2	7	-7	8	3	5	7	1.317584	1.251146	0.066438	5.04%	<10%
-1	-3	0	4	0	-6	-6	0	0	4	5	1.544174	0.898205	0.645969	41.83%	<50%
-3	4	3	1	3	3	3	3	3	3	0	0.851466	1.119461	0.267995	31.47%	<40%
-2	0	0	0	3	0	-6	6	0	0	0	1.206121	1.190728	0.015393	1.28%	<5%
-2	0	0	0	0	0	-1	0	3	0	4	0.929054	0.795536	0.133518	14.37%	<20%
8	8	0	5	6	4	-5	7	4	0	0	1.112842	0.972064	0.140779	12.65%	<20%
-8	0	5	5	0	0	-4	6	7	7	8	1.014784	0.966394	0.048389	4.77%	<5%
-1	6	0	2	9	-9	-4	5	6	4	2	0.970372	1.087262	0.116890	12.05%	<20%
0	0	0	0	0	-5	2	3	1	0	0	1.071638	1.469013	0.397375	37.08%	<40%
0	0	4	7	0	-5	-8	3	4	3	4	1.346075	1.193779	0.152296	11.31%	<20%
5	6	0	7	0	0	0	5	2	0	7	1.114074	1.051575	0.062499	5.61%	<10%
5	5	0	5	0	4	-2	8	5	0	5	1.164404	0.982224	0.182180	15.65%	<20%
0	0	0	0	0	0	0	0	0	4	9	1.152380	0.976223	0.176156	15.29%	<20%
0	6	0	5	4	0	-5	0	7	0	5	1.065070	0.867596	0.197474	18.54%	<20%
2	3	0	0	4	-4	0	0	3	0	2	0.985885	1.448022	0.462137	46.88%	<50%
8	8	0	7	0	8	7	7	5	0	5	1.033466	1.377123	0.343657	33.25%	<40%
0	0	0	1	0	-5	-6	0	3	0	0	1.358482	1.287544	0.070939	5.22%	<10%
6	7	0	9	0	8	-9	0	7	0	7	1.051095	0.941065	0.110030	10.47%	<20%
0	4	0	4	0	-4	-7	0	5	7	6	0.896466	1.039970	0.143505	16.01%	<20%
5	5	0	4	3	-4	-4	5	2	0	5	1.748705	1.484059	0.264646	15.13%	<20%
0	0	0	2	9	-9	-8	9	8	0	5	0.960915	1.184163	0.223247	23.23%	<30%
4	7	0	2	2	-4	0	4	4	4	7	1.042492	1.251618	0.209127	20.06%	<30%
-5	0	0	5	8	-5	-7	0	5	0	0	1.055807	0.992588	0.063219	5.99%	<10%
0	-1	0	1	0	-1	-1	1	1	1	1	0.995463	0.913385	0.082078	8.25%	<10%
-4	-8	0	0	0	0	0	0	0	0	0	1.160240	1.378228	0.217988	18.79%	<20%
3	6	2	5	5	-8	-8	0	7	3	6	0.900958	1.030227	0.129269	14.35%	<20%
-1	1	1	0	7	-5	-3	0	7	8	8	1.089557	1.104982	0.015425	1.42%	<5%
-4	0	1	0	0	-6	-1	6	6	0	5	1.005266	0.893232	0.112035	11.14%	<20%
5	5	0	0	0	7	-5	4	6	6	0	0.903650	1.014152	0.110502	12.23%	<20%
-9	-3	7	3	7	-5	-6	0	4	0	4	1.168117	1.127270	0.040847	3.50%	<5%
-8	0	0	0	0	0	0	0	0	0	0	1.126423	1.663541	0.537118	47.68%	<50%
0	0	8	0	7	0	-6	6	0	5	7	1.070291	0.741094	0.329197	30.76%	<40%

## ANEXOS- Resultados Experimentais

x 0	x 1	x 2	x 3	x 4	x 5	x 6	x 7	x 8	x 9	x 10	y	y'	error	error(%)	Cat
-1	7	0	6	1	-8	-7	4	8	3	8	0.725663	0.980759	0.255096	35.15%	<40%
-5	9	0	6	0	0	-8	0	8	0	9	1.128765	1.200179	0.071414	6.33%	<10%
-4	-8	0	0	0	-8	-5	7	9	0	8	0.942895	0.742141	0.200754	21.29%	<30%
1	1	0	7	0	7	0	0	0	0	0	1.682267	1.076063	0.606204	36.03%	<40%
0	5	0	8	6	7	-7	8	6	3	5	1.039708	1.392694	0.352985	33.95%	<40%
0	0	0	0	0	0	-5	1	1	8	8	1.074053	0.856243	0.217809	20.28%	<30%
1	5	0	5	0	7	-7	0	5	4	6	1.075401	1.081822	0.006421	0.60%	<5%
7	7	0	7	0	-7	0	0	0	0	0	1.160938	1.345611	0.184674	15.91%	<20%
-5	0	5	0	5	9	0	5	7	5	5	1.050794	1.233096	0.182302	17.35%	<20%
4	9	0	8	0	6	0	0	0	9	0	1.206074	1.403145	0.197071	16.34%	<20%
0	0	5	1	0	7	0	7	7	0	9	1.085725	1.176820	0.091095	8.39%	<10%
5	9	0	0	0	9	-5	5	9	9	0	0.978223	0.963441	0.014782	1.51%	<5%
5	6	0	5	0	5	-5	5	0	0	0	1.365333	1.238001	0.127333	9.33%	<10%

*Tabela A-33: Resultados previsão através RNA (Net Console) Ano 2014*

### Net Console: Modelo Estratégico 2015

x 0	x 1	x 2	x 3	x 4	x 5	x 6	x 7	x 8	x 9	x 10	y	y'	error	error(%)	Cat
5	8	0	0	0	5	-5	0	0	0	0	0.956714	1.268548	0.311834	32.59%	<40%
3	7	0	5	0	3	0	0	0	0	0	1.822236	1.231505	0.590732	32.42%	<40%
-2	-1	7	0	1	0	-5	5	5	5	7	1.365615	1.015037	0.350578	25.67%	<30%
-5	0	1	5	0	-9	-5	7	0	5	9	0.916470	1.231808	0.315338	34.41%	<40%
7	7	0	6	0	0	-6	0	0	0	6	1.484693	1.405491	0.079202	5.33%	<10%
-6	6	3	4	0	3	0	4	4	0	0	1.051615	1.120841	0.069226	6.58%	<10%
-7	8	5	5	7	7	-7	0	0	6	6	1.002269	1.288446	0.286177	28.55%	<30%
-8	6	3	8	5	0	-8	5	3	7	5	0.957998	1.153358	0.195359	20.39%	<30%
-2	7	0	4	0	-6	-4	0	0	2	4	1.032286	1.154864	0.122578	11.87%	<20%
0	0	0	5	4	-3	-1	0	2	0	0	1.199813	0.960517	0.239296	19.94%	<20%
-1	6	0	2	9	-9	-4	6	6	4	2	1.634246	1.039556	0.594690	36.33%	<40%
0	0	0	5	0	-7	0	8	7	0	8	0.994100	1.391780	0.397672	40.00%	<50%
0	0	0	0	0	-7	3	4	1	0	0	1.225837	1.179307	0.046530	3.80%	<5%
-6	-1	9	2	0	8	-6	0	0	8	9	0.764718	1.202298	0.437529	57.22%	>50%
0	9	0	8	0	6	-8	7	5	7	6	1.368309	1.198797	0.169513	12.39%	<20%
0	0	6	0	8	6	-5	8	6	6	5	0.655136	0.856323	0.201186	30.71%	<40%
6	7	0	0	0	-8	0	8	6	0	0	1.118042	0.882441	0.235601	21.07%	<30%
0	0	0	5	5	-5	0	0	0	5	9	1.022409	0.920985	0.101424	9.92%	<10%
3	5	0	1	3	6	-4	1	0	0	2	0.795546	1.102257	0.306711	38.55%	<40%
-3	0	0	0	0	2	0	2	6	0	0	1.076272	1.241103	0.164831	15.31%	<20%
0	-6	0	0	0	0	-5	0	0	0	4	1.237125	1.263882	0.026757	2.16%	<5%
1	-2	0	5	3	-3	-3	1	0	5	3	1.010494	0.893997	0.116497	11.53%	<20%
4	6	4	6	5	8	-6	0	2	0	2	1.114784	1.121858	0.007075	0.63%	<5%
8	8	0	7	0	8	7	7	5	0	5	1.070174	1.357764	0.287591	26.87%	<30%
7	7	0	6	0	-6	-6	6	6	6	6	1.153149	1.164605	0.011456	0.99%	<5%
0	0	5	3	0	-6	3	0	6	3	4	1.117351	0.918487	0.198865	17.80%	<20%
1	6	0	1	0	7	-8	2	8	0	6	1.237102	0.745413	0.491689	39.75%	<40%
0	8	0	0	0	7	-7	0	8	0	0	0.791886	0.995166	0.203480	25.70%	<40%
5	7	0	5	4	-4	0	8	8	5	7	1.117515	1.097874	0.019641	1.76%	<5%
-5	6	2	7	1	-7	0	0	6	7	7	1.018175	1.125206	0.107031	10.51%	<20%
2	2	0	4	0	5	3	5	8	6	0	1.032881	1.039150	0.006268	0.61%	<5%
5	8	0	5	0	0	0	0	0	0	5	1.519736	1.556529	0.036793	2.42%	<5%
-3	-5	2	3	3	-5	-5	5	5	1	3	0.915255	1.048039	0.132785	14.51%	<20%
-2	0	0	2	0	6	-3	0	0	0	0	1.140544	1.215068	0.074523	6.53%	<10%
0	7	6	0	5	-5	-5	3	0	3	6	1.039601	1.469866	0.430265	41.39%	<50%
5	5	0	0	4	7	-5	4	2	0	4	1.600406	1.112273	0.488133	30.50%	<40%
6	7	0	3	0	7	0	0	7	2	8	0.957344	1.077210	0.119867	12.52%	<20%
4	5	7	7	5	-5	-5	2	2	6	3	1.016712	1.023135	0.006422	0.63%	<5%
-3	3	0	1	0	-5	-4	0	4	3	4	1.070813	1.072207	0.001394	0.13%	<5%
-5	9	0	7	0	0	-9	0	9	0	9	1.259282	1.039329	0.219954	17.47%	<20%
6	7	0	3	0	-7	-7	6	2	0	0	1.068530	1.186884	0.118354	11.08%	<20%
-4	0	0	7	0	-7	-8	7	6	4	7	1.149480	1.277729	0.128250	11.16%	<20%
5	5	0	0	0	0	-4	3	0	0	0	1.121155	1.394112	0.272957	24.35%	<30%
6	7	0	8	0	7	-9	0	7	7	7	1.372882	1.050010	0.322872	23.52%	<30%
9	0	5	6	8	-6	-8	1	7	0	9	1.094185	1.087194	0.006992	0.64%	<5%
-7	6	0	1	3	4	-6	7	5	0	5	1.285015	1.152299	0.142716	11.02%	<20%
2	3	0	3	0	5	-4	0	4	0	0	1.561452	0.911723	0.649722	41.61%	<50%
0	7	0	4	0	6	0	3	0	0	0	1.791574	0.950679	0.840895	46.94%	<50%
4	4	0	1	0	7	0	0	3	0	0	0.960456	1.228378	0.267922	27.90%	<30%

*Tabela A-34: Resultados previsão através RNA (Net Console) Ano 2015*

### Net Console: Modelo Estratégico Total 2013 – Conjunto Avaliação 2014

x 0	x 1	x 2	x 3	x 4	x 5	x 6	x 7	x 8	x 9	x 10	y	y'	error	error(%)	Cat
2	6	7	0	0	2	-3	0	0	0	0	0.928802	1.508300	0.579497	62.39%	>50%
-1	0	0	6	8	-7	-6	0	0	5	7	0.918333	1.234441	0.316109	34.42%	<40%
0	6	0	6	9	0	0	0	0	0	0	1.143877	0.908401	0.235475	20.59%	<30%
5	9	0	6	6	0	0	4	5	4	7	1.009430	1.152448	0.143019	14.17%	<20%
-5	0	2	0	0	0	-1	5	0	0	0	1.043110	0.635989	0.407121	39.03%	<40%
0	0	0	0	0	0	0	0	0	4	8	0.964350	1.018901	0.054551	5.66%	<10%
0	9	0	9	5	9	-9	0	6	0	8	1.250142	1.118359	0.131782	10.54%	<20%
7	8	3	0	0	8	-8	7	5	0	0	1.190558	0.913705	0.276853	23.25%	<30%
-6	-5	0	6	0	0	0	7	0	6	5	0.947157	1.014838	0.067681	7.15%	<10%
1	4	0	8	0	1	-3	0	4	0	0	1.084289	1.102645	0.018356	1.69%	<5%
2	3	0	2	9	4	-3	4	0	0	4	1.204302	0.660834	0.543468	45.13%	<50%
0	-4	3	5	0	0	-1	0	0	0	2	1.351553	0.809359	0.542194	40.12%	<50%
0	2	0	0	6	3	-2	0	0	1	3	1.060329	0.775015	0.285314	26.91%	<30%
1	1	3	0	2	3	3	4	2	6	6	0.653442	1.020372	0.366931	56.15%	>50%
2	5	0	3	4	-4	-6	0	5	0	0	0.860568	0.976201	0.115633	13.44%	<20%
0	7	0	7	0	-8	-6	0	6	7	8	1.248302	1.025285	0.223017	17.87%	<20%
-3	-3	2	3	9	-3	-7	7	4	4	7	1.090231	1.100865	0.010634	0.98%	<5%
0	3	0	2	0	-4	-4	4	3	0	8	1.411784	1.547144	0.135360	9.59%	<10%

# ANEXOS- Resultados Experimentais

x 0	x 1	x 2	x 3	x 4	x 5	x 6	x 7	x 8	x 9	x 10	y	y'	error	error(%)	Cat
6	7	0	5	4	5	-6	6	2	6	3	1.207631	1.136283	0.071348	5.91%	<10%
-6	6	6	4	5	0	-7	5	3	5	5	1.080613	1.147010	0.066398	6.14%	<10%
-8	7	0	0	0	6	-2	2	7	0	0	1.247960	0.806493	0.441467	35.38%	<40%
0	0	0	5	0	-2	-1	0	1	0	0	0.857568	1.086272	0.228704	26.67%	<30%
-2	-1	2	4	2	-5	-7	0	3	3	6	0.950667	1.159951	0.209285	22.01%	<30%
-2	6	0	3	0	6	-8	7	7	0	0	1.013482	1.037217	0.023735	2.34%	<5%
0	5	4	0	6	-9	-9	9	0	0	0	1.235492	0.757171	0.478322	38.72%	<40%
0	9	0	6	0	-4	-7	7	9	0	0	0.991480	1.188347	0.196867	19.86%	<20%
-1	-2	2	5	7	-5	-4	5	6	5	7	1.155543	1.213224	0.057681	4.99%	<5%
0	2	0	2	0	3	3	0	0	0	0	0.981377	1.181080	0.199703	20.35%	<30%
-4	1	1	2	0	4	-4	3	4	4	5	0.884294	1.203943	0.319649	36.15%	<40%
-4	0	0	6	0	-7	0	8	7	0	8	1.039133	1.224090	0.184957	17.80%	<20%
0	5	0	4	3	-5	0	5	0	0	0	1.041357	0.922690	0.118667	11.40%	<20%
4	7	1	7	4	7	0	8	8	4	4	1.308145	1.612369	0.304223	23.26%	<30%
-6	-1	9	2	0	-6	-6	0	0	8	9	1.126189	1.044719	0.081470	7.23%	<10%
0	5	0	5	0	-6	0	5	5	0	5	1.205552	1.142933	0.062619	5.19%	<10%
-2	0	0	0	7	9	-7	2	6	2	8	1.051058	1.366084	0.315026	29.97%	<30%
-6	0	0	0	0	6	-5	0	6	0	6	0.617245	1.034628	0.417383	67.62%	>50%
-2	-4	6	0	0	0	-4	2	0	0	6	0.606973	0.864228	0.257256	42.38%	<50%
0	8	0	8	6	-6	-5	7	0	0	8	1.039381	1.073734	0.034354	3.31%	<5%
3	7	0	0	0	-8	0	8	6	0	0	1.050357	0.912899	0.137458	13.09%	<20%
0	7	0	2	2	-5	-3	0	3	7	0	0.861289	1.163817	0.302528	35.12%	<40%
-4	9	0	8	0	-9	-1	0	0	0	2	1.243631	1.363957	0.120327	9.68%	<10%
6	6	0	0	0	6	0	6	8	0	0	1.169874	0.997602	0.172273	14.73%	<20%
0	0	4	0	9	0	1	1	0	0	0	0.906773	0.840266	0.066507	7.33%	<10%
0	0	0	5	5	-5	0	0	0	5	9	0.951963	0.925998	0.025964	2.73%	<5%
-3	8	0	2	0	0	-6	0	0	0	7	1.209131	1.151881	0.057250	4.73%	<5%
1	4	2	0	0	8	2	8	8	0	8	1.076004	0.818075	0.257929	23.97%	<30%
0	7	0	0	6	-6	-7	0	4	0	6	1.258927	0.989826	0.269101	21.38%	<30%
-8	0	6	1	2	1	4	2	3	2	4	1.192813	0.922876	0.269937	22.63%	<30%
-5	-5	5	5	5	5	5	5	5	5	5	1.012584	0.876810	0.135774	13.41%	<20%
2	4	0	0	0	6	-4	1	0	0	2	1.292317	1.147258	0.145059	11.22%	<20%
0	8	0	5	0	0	-9	0	9	3	0	0.943335	1.364915	0.421580	44.69%	<50%
1	3	0	0	2	2	3	3	3	0	4	0.998372	0.894181	0.104191	10.44%	<20%
4	-5	5	6	6	5	0	5	6	6	6	1.748827	1.420992	0.327835	18.75%	<20%
0	-5	6	0	0	4	-6	0	7	6	6	0.999312	0.796221	0.203091	20.32%	<30%
-6	3	0	2	0	2	-4	0	0	1	2	0.966205	0.909487	0.056718	5.87%	<10%
0	7	1	3	6	-5	7	3	4	3	1	0.954187	0.952036	0.002150	0.23%	<5%
1	-1	0	1	0	0	-2	1	0	0	2	1.042776	1.189397	0.146622	14.06%	<20%
-7	9	8	9	0	0	0	0	0	0	6	0.731407	1.770457	1.039050	142.06%	>50%
-2	-2	2	6	9	-7	-8	3	5	7	4	1.167652	1.140872	0.026780	2.29%	<5%
-5	-3	5	0	6	-5	-5	6	7	7	2	0.906308	0.911096	0.004787	0.53%	<5%
4	7	0	0	0	0	0	4	0	0	0	1.237724	0.765412	0.472312	38.16%	<40%
7	6	0	5	0	-5	-5	5	5	5	5	1.963121	0.873042	1.090079	55.53%	>50%
-7	-5	0	4	0	-4	-3	0	4	4	0	1.069433	1.077268	0.007835	0.73%	<5%
1	5	0	1	0	7	-8	2	8	0	4	1.217599	1.215397	0.002202	0.18%	<5%
5	4	0	5	0	-6	-5	0	2	0	4	1.395801	1.164176	0.231625	16.59%	<20%
0	0	3	0	0	0	-3	0	3	2	0	0.863325	1.383428	0.520102	60.24%	>50%
6	5	1	5	0	6	0	0	5	0	6	1.501725	1.374171	0.127554	8.49%	<10%
0	8	0	0	0	7	-7	0	8	0	0	0.991862	1.106532	0.114670	11.56%	<20%
3	6	0	8	0	-4	0	7	8	7	4	1.056163	1.185244	0.129081	12.22%	<20%
0	0	0	0	0	-5	0	0	0	4	4	0.523596	1.191910	0.668314	127.64%	>50%
5	8	0	4	0	-8	-1	8	6	7	4	0.983626	0.741652	0.241974	24.60%	<30%
-2	5	0	0	8	6	-3	7	5	0	0	1.151123	0.867062	0.284061	24.68%	<30%
-4	4	0	4	4	3	-4	0	0	4	4	0.966179	1.055699	0.089520	9.27%	<10%
0	0	0	6	0	-6	-7	6	6	6	0	1.077110	1.197285	0.120175	11.16%	<20%
-5	3	3	5	3	-5	0	0	5	5	6	1.286815	1.104633	0.182181	14.16%	<20%
5	5	0	5	0	-5	-5	5	5	5	9	1.148636	1.083932	0.064704	5.63%	<10%
-6	5	0	5	0	-3	-4	3	3	2	5	1.140013	1.184487	0.044474	3.90%	<5%
7	6	0	4	0	6	3	5	8	5	0	1.172905	1.331553	0.158648	13.53%	<20%
3	4	0	4	3	5	-4	3	5	5	4	1.286104	1.134354	0.151750	11.80%	<20%
0	7	3	0	5	-5	-5	3	2	2	4	1.182172	0.753703	0.428468	36.24%	<40%
0	5	0	5	0	5	0	0	5	0	3	1.267984	1.332951	0.064967	5.12%	<10%
5	7	0	0	1	5	-7	8	8	2	0	1.088313	1.087229	0.001084	0.10%	<5%
1	2	0	2	3	-3	-3	3	0	1	2	1.261402	1.030189	0.231213	18.33%	<20%
4	6	0	2	0	6	0	0	4	0	6	1.035027	1.250773	0.215746	20.84%	<30%
-7	7	0	4	0	0	-8	0	8	0	6	0.949922	1.075316	0.125394	13.20%	<20%
-9	9	0	5	0	-9	-9	0	5	0	0	1.364205	1.410600	0.046395	3.40%	<5%
-3	3	0	1	0	0	-3	0	3	1	2	1.155945	1.108645	0.047301	4.09%	<5%
3	5	0	0	0	2	-9	7	9	5	9	1.039025	1.024867	0.014158	1.36%	<5%
5	3	6	5	5	5	0	6	6	6	7	0.989742	1.192159	0.202417	20.45%	<30%
0	4	0	4	0	7	-2	0	3	0	0	0.987462	0.945609	0.041853	4.24%	<5%
5	6	0	6	0	6	-5	2	4	0	4	0.780952	1.266863	0.485911	62.22%	>50%
-3	0	0	3	0	-6	-6	5	2	2	6	1.379783	1.008942	0.370841	26.88%	<30%
-7	0	2	4	0	0	0	9	2	7	9	1.029110	1.162629	0.133518	12.97%	<20%
-5	4	0	2	0	0	0	0	3	2	0	0.972023	0.865408	0.106616	10.97%	<20%
-3	6	0	6	5	-4	8	0	0	6	0	1.130513	1.074066	0.056447	4.99%	<5%
1	5	0	1	0	-2	0	0	0	0	0	1.274228	1.186922	0.087306	6.85%	<10%
0	9	3	9	0	-5	9	0	5	8	6	1.758377	1.325877	0.432500	24.60%	<30%
0	0	0	0	0	1	0	0	0	0	8	0.908567	1.105318	0.196750	21.66%	<30%
6	5	0	9	0	6	-4	6	4	0	4	0.711251	1.331197	0.619946	87.16%	>50%
0	0	0	9	0	-9	-9	5	9	0	5	1.345740	1.224564	0.121176	9.00%	<10%
0	8	0	3	9	-5	-5	3	5	0	5	1.106267	1.121091	0.014824	1.34%	<5%
0	9	0	0	0	9	-3	9	5	0	2	1.490860	1.012692	0.478168	32.07%	<40%
0	0	8	9	0	-9	-9	5	5	0	0	1.763228	1.126918	0.636310	36.09%	<40%
-4	4	0	0	0	0	-3	0	4	4	4	1.151706	1.308495	0.156788	13.61%	<20%
-1	-1	0	0	0	-7	0	1	7	0	4	1.081382	1.101838	0.070544	6.52%	<10%
-6	0	0	5	0	5	0	0	6	0	7	1.043067	0.954364	0.088703	8.50%	<10%
-2	-1	7	0	1	0	-4	4	3	1	7	0.844564	1.002451	0.157887	18.69%	<20%
-5	-1	5	4	2	-6	-4	3	2	4	6	0.562434	0.970154	0.407720	72.49%	>50%
1	4	0	3	0	0	0	3	6	0	0	1.133157	0.864276	0.268881	23.73%	<30%
0	4	0	2	0	-5	-4	0	0	2	3	0.965855	1.297837	0.331982	34.37%	<40%
-5	7	5	7	5	6	-5	3	0	4	5	0.987610	1.088507	0.100897	10.22%	<20%
-6	6	0	0	8	0	-2	4	0	0	3	0.917597	0.627139	0.290458	31.65%	<40%
5	4	0	0	0	0	-1	6	6	0	5	0.864773	0.931997	0.067224	7.77%	&

## ANEXOS- Resultados Experimentais

x 0	x 1	x 2	x 3	x 4	x 5	x 6	x 7	x 8	x 9	x 10	y	y'	error	error(%)	Cat
-7	0	8	7	7	0	0	0	0	0	3	1.144752	1.077056	0.067695	5.91%	<10%
-3	0	0	2	7	3	-5	5	4	5	6	1.106980	0.916414	0.190566	17.21%	<20%
2	4	0	5	0	5	-5	5	1	4	2	1.485567	1.303984	0.181583	12.22%	<20%
0	7	2	6	0	-7	-6	5	5	0	0	1.072213	1.061823	0.010390	0.97%	<5%
0	0	0	4	0	0	0	0	2	0	5	1.090583	0.902060	0.188524	17.29%	<20%
3	1	0	4	0	-4	-3	4	3	0	0	1.191054	1.065779	0.125276	10.52%	<20%
0	0	0	2	0	-1	-3	4	2	0	1	1.234972	0.895803	0.339169	27.46%	<30%
1	2	0	4	3	-3	-6	4	4	5	0	1.107694	1.056419	0.051275	4.63%	<5%
-6	3	8	1	6	0	-2	1	3	7	7	0.977225	1.159812	0.182587	18.68%	<20%
0	0	0	0	5	0	0	0	5	6	9	1.037107	1.038722	0.001615	0.16%	<5%
-6	-3	0	0	0	0	0	0	0	0	0	1.320111	1.101201	0.218910	16.58%	<20%
0	0	0	7	0	0	-6	7	6	0	0	0.977081	1.018510	0.041428	4.24%	<5%
-6	0	5	7	0	0	-7	3	4	4	7	1.237124	1.210462	0.026662	2.16%	<5%
1	3	0	7	0	6	-5	4	6	2	5	1.108880	1.166212	0.057332	5.17%	<10%
-4	0	0	4	1	-3	-4	4	2	1	4	1.524711	1.042510	0.482201	31.63%	<40%
0	0	0	5	0	-6	-7	7	5	0	9	1.216466	1.361657	0.145191	11.94%	<20%
5	6	0	1	0	0	4	0	0	0	0	1.327686	1.409134	0.081448	6.13%	<10%
0	5	9	0	0	5	-5	5	0	5	0	1.005291	1.005592	0.000302	0.03%	<5%
4	5	0	5	2	7	-7	8	3	5	7	1.317584	1.225032	0.092553	7.02%	<10%
-1	-3	0	4	0	-6	-6	0	0	4	5	1.544174	0.894458	0.649716	42.08%	<50%
-3	4	3	1	3	3	3	3	3	3	0	0.851466	0.631055	0.220411	25.89%	<30%
-2	0	0	0	3	0	-6	6	0	0	0	1.206121	0.605693	0.600428	49.78%	<50%
-2	0	0	0	0	0	-1	0	3	0	4	0.929054	0.881049	0.048006	5.17%	<10%
8	8	0	5	6	4	-5	7	4	0	0	1.112842	0.873794	0.239049	21.48%	<30%
-8	0	5	5	0	-4	-6	7	7	8	8	1.014784	1.066900	0.052116	5.14%	<10%
-1	6	0	2	9	-9	-4	5	6	4	2	0.970372	1.180137	0.209765	21.62%	<30%
0	0	0	0	0	-5	2	3	1	0	0	1.071638	0.863024	0.208613	19.47%	<20%
0	0	4	7	0	-5	-8	3	4	3	4	1.346075	1.339018	0.007057	0.52%	<5%
5	6	0	7	0	0	0	5	2	0	7	1.114074	1.199130	0.085055	7.63%	<10%
5	5	0	5	0	4	-2	8	5	0	5	1.164404	1.143126	0.021278	1.83%	<5%
0	0	0	0	0	0	0	0	0	4	9	1.152380	1.042451	0.109929	9.54%	<10%
0	6	0	5	4	0	-5	0	7	0	5	1.065070	1.123900	0.058831	5.52%	<10%
2	3	0	0	4	-4	0	0	3	0	2	0.985885	0.957614	0.028271	2.87%	<5%
8	8	0	7	0	8	7	7	5	0	5	1.033466	1.243981	0.210516	20.37%	<30%
0	0	0	1	0	-5	-6	0	3	0	0	1.358482	1.063833	0.294649	21.69%	<30%
6	7	0	9	0	8	-9	0	7	0	7	1.051095	1.228366	0.177271	16.87%	<20%
0	4	0	4	0	-4	-7	0	5	7	6	0.896466	1.109814	0.213348	23.80%	<30%
5	5	0	4	3	-4	-4	5	2	0	5	1.748705	0.731788	1.016918	58.15%	>50%
0	0	0	2	9	-9	-8	9	8	0	5	0.960915	1.104593	0.143678	14.95%	<20%
4	7	0	2	2	-4	0	4	4	4	7	1.042492	0.997717	0.044775	4.29%	<5%
-5	0	0	5	8	-5	-7	0	5	0	0	1.055807	0.874689	0.181118	17.15%	<20%
0	-1	0	1	0	-1	-1	1	1	1	1	0.995463	0.921717	0.073746	7.41%	<10%
-4	-8	0	0	0	0	0	0	0	0	0	1.160240	1.287323	0.127084	10.95%	<20%
3	6	2	5	5	-8	-8	0	7	3	6	0.900958	0.989705	0.088747	9.85%	<10%
-1	1	1	0	7	-5	-3	0	7	8	8	1.089557	1.271461	0.181903	16.70%	<20%
-4	0	1	0	0	-6	-1	6	6	0	5	1.005266	1.149478	0.144211	14.35%	<20%
5	5	0	0	0	7	-5	4	6	6	0	0.903650	1.322342	0.418692	46.33%	<50%
-9	-3	7	3	7	-5	-6	0	4	0	4	1.168117	1.083654	0.084463	7.23%	<10%
-8	0	0	0	0	0	0	0	0	0	0	1.126423	1.019489	0.106933	9.49%	<10%
0	0	8	0	7	0	-6	6	0	5	7	1.070291	0.857686	0.212605	19.86%	<20%
1	7	0	6	1	-8	-7	4	8	3	8	0.725663	1.026175	0.300512	41.41%	<50%
-5	9	0	6	0	0	-8	0	8	0	9	1.128765	1.042074	0.086691	7.68%	<10%
-4	-8	0	0	0	-8	-5	7	9	0	8	0.942895	0.994315	0.051420	5.45%	<10%
1	1	0	7	0	7	0	0	0	0	0	1.682267	1.084769	0.597498	35.52%	<40%
0	5	0	8	6	7	-7	8	6	3	5	1.039708	1.097242	0.057534	5.53%	<10%
0	0	0	0	0	0	-5	1	1	8	8	1.074053	1.264349	0.190297	17.72%	<20%
1	5	0	5	0	7	-7	0	5	4	6	1.075401	1.446482	0.371081	34.51%	<40%
7	7	0	7	0	-7	0	0	0	0	0	1.160938	1.529892	0.368954	31.78%	<40%
-5	0	5	0	5	9	0	5	7	5	5	1.050794	1.166286	0.115491	10.99%	<20%
4	9	0	8	0	6	0	0	0	9	0	1.206074	1.255699	0.049625	4.11%	<5%
0	0	5	1	0	7	0	7	7	0	9	1.085725	1.009195	0.076530	7.05%	<10%
5	9	0	0	0	9	-5	5	9	9	0	0.978223	1.302273	0.324050	33.13%	<40%
5	6	0	5	0	5	-5	5	0	0	0	1.365333	1.006941	0.358392	26.25%	<30%

Tabela A-35: Resultados previsão através RNA (Net Console) Conjunto Treino 2013 e Conjunto Teste 2014

### Net Console: Modelo Estratégico Total 2014 – Conjunto Avaliação 2015

x 0	x 1	x 2	x 3	x 4	x 5	x 6	x 7	x 8	x 9	x 10	y	y'	error	error(%)	Cat
-1	0	0	4	0	-6	-7	0	0	4	5	0.848661	1.357555	0.508895	59.96%	>50%
-1	0	0	8	8	-7	-6	0	0	6	7	0.990433	0.868381	0.122052	12.32%	<20%
-5	7	0	8	7	8	-8	8	0	0	8	1.034696	1.384687	0.349991	33.83%	<40%
0	6	0	9	0	0	0	0	0	0	0	1.028764	1.416598	0.387834	37.70%	<40%
0	5	3	7	0	-3	-5	0	6	4	6	1.129105	0.978478	0.150626	13.34%	<20%
-6	0	0	5	0	5	0	0	6	0	7	0.902499	1.039870	0.137370	15.22%	<20%
-7	0	0	0	0	0	-1	5	0	0	0	0.960759	0.934522	0.026237	2.73%	<5%
-3	5	3	1	3	3	3	3	3	4	0	0.913967	0.736527	0.177440	19.41%	<20%
0	9	0	9	5	9	-9	0	6	0	8	1.134540	1.251714	0.117174	10.33%	<20%
7	-5	5	0	7	0	-5	0	7	0	0	0.730360	1.372237	0.641877	87.89%	>50%
0	0	7	7	6	0	-8	7	8	6	7	1.170733	0.984107	0.186626	15.94%	<20%
-6	-5	0	6	0	0	0	7	0	6	5	1.118681	0.947648	0.171033	15.29%	<20%
-3	0	0	3	4	0	-4	3	0	0	0	1.023998	1.207226	0.183229	17.89%	<20%
0	4	3	5	0	0	-1	0	0	0	4	1.716123	1.307282	0.408841	23.82%	<30%
2	2	0	2	6	3	-4	0	0	4	3	1.015234	1.200603	0.185369	18.26%	<20%
2	5	0	3	3	-6	-7	0	4	0	0	0.952840	0.985362	0.032522	3.41%	<5%
-3	-3	2	4	9	-4	-7	7	4	4	7	1.074061	1.066064	0.007997	0.75%	<5%
6	7	0	5	4	5	-6	6	2	6	3	1.452449	1.210819	0.241629	16.64%	<20%
-8	0	0	8	5	0	-4	6	7	7	8	0.956453	1.066313	0.109860	11.49%	<20%
-1	-1	2	5	2	-5	-7	0	8	3	6	0.985659	1.013911	0.028253	2.87%	<5%
-2	6	0	8	0	7	-7	7	8	0	0	1.155223	1.217206	0.061984	5.37%	<10%
0	5	4	0	6	-9	-9	9	0	0	0	1.055143	1.237093	0.181950	17.24%	<20%
0	9	0	6	0	-4	-7	7	9	0	0	0.756419	0.993329	0.236910	31.32%	<40%
3	5	0	5	6	-7	-5	0	3	7	7	1.035128	0.883639	0.151489	14.64%	<20%

# ANEXOS- Resultados Experimentais

x 0	x 1	x 2	x 3	x 4	x 5	x 6	x 7	x 8	x 9	x 10	y	y'	error	error(%)	Cat
0	-5	5	6	0	5	0	5	0	0	7	0.788643	1.512430	0.723787	91.78%	>50%
0	2	0	2	0	3	3	0	2	0	0	1.012741	1.103838	0.091097	9.00%	<10%
-5	2	2	4	0	6	-5	5	4	7	8	1.200289	0.858940	0.341349	28.44%	<30%
0	5	0	4	4	4	0	5	0	0	0	1.084904	1.053234	0.031670	2.92%	<5%
5	8	1	8	5	8	0	9	9	4	4	1.285187	1.281721	0.003465	0.27%	<5%
0	0	4	7	0	-5	-8	3	4	3	4	0.943830	1.343347	0.399518	42.33%	<50%
-2	0	0	0	0	9	-7	2	5	2	8	1.204803	1.349358	0.144554	12.00%	<20%
8	8	0	8	0	0	0	5	2	0	0	1.244059	1.550032	0.305972	24.60%	<30%
0	8	0	8	0	8	-7	3	6	5	7	0.986843	0.999217	0.012375	1.25%	<5%
0	0	0	0	0	-7	0	0	8	0	0	1.166349	1.245834	0.079485	6.82%	<10%
-4	9	0	8	0	-9	-1	0	0	0	2	1.171292	1.242919	0.071627	6.12%	<10%
5	5	0	0	0	9	-9	6	9	0	9	0.600623	1.070661	0.470037	78.26%	>50%
-4	5	0	0	0	5	0	8	5	0	5	1.128345	1.046903	0.081443	7.22%	<10%
-4	-7	9	9	0	-6	6	2	7	2	3	1.104484	1.013570	0.090914	8.23%	<10%
0	6	0	6	0	6	0	6	8	0	0	1.032731	1.122666	0.089935	8.71%	<10%
1	1	0	7	0	0	-2	2	0	0	2	0.898976	1.059753	0.160777	17.88%	<20%
-9	-8	1	8	5	0	0	0	7	0	8	1.227912	0.945977	0.281935	22.96%	<30%
-5	0	0	3	4	-4	-8	0	0	4	9	1.003797	1.035752	0.031955	3.18%	<5%
0	0	0	0	0	0	0	0	9	9	9	1.111399	0.808705	0.302694	27.24%	<30%
0	7	0	8	6	-6	-7	0	4	5	6	1.024957	0.935840	0.089117	8.70%	<10%
-7	0	7	2	4	2	6	5	6	3	7	1.711891	0.897060	0.814832	47.60%	<50%
5	0	5	0	0	-5	-5	6	6	5	5	1.044188	1.133014	0.088825	8.51%	<10%
5	5	0	8	0	6	0	5	4	0	5	1.141939	1.030208	0.111731	9.78%	<10%
-5	-5	5	5	5	5	5	5	5	0	5	0.993801	0.941754	0.052047	5.24%	<10%
4	9	0	8	0	0	0	0	9	0	0	1.421858	1.233010	0.188848	13.28%	<20%
2	-2	0	0	1	2	2	3	2	0	4	0.937685	1.264253	0.326568	34.83%	<40%
2	3	0	0	4	-4	0	0	3	0	2	0.999656	0.991279	0.008376	0.84%	<5%
0	0	1	2	5	7	-7	0	7	1	1	0.973624	1.053132	0.079507	8.17%	<10%
-6	3	0	2	0	2	-4	0	0	1	2	1.156288	0.970745	0.185543	16.05%	<20%
5	-5	0	6	0	6	8	0	9	0	9	1.026098	1.699470	0.673372	65.63%	>50%
-6	0	4	4	4	6	-6	7	3	3	6	1.017821	0.985888	0.031933	3.14%	<5%
-7	7	1	0	3	8	-8	8	5	5	7	1.150927	1.124884	0.026043	2.26%	<5%
-5	7	5	7	6	-6	-6	6	7	6	1	1.014754	1.007687	0.007067	0.70%	<5%
-6	-2	0	8	0	-8	-9	8	7	8	0	0.847688	1.119848	0.272161	32.11%	<40%
-6	-5	0	5	0	-4	-3	0	4	5	0	0.947428	1.097945	0.150517	15.89%	<20%
2	6	0	9	0	7	-6	5	1	9	7	0.913640	1.208064	0.294424	32.23%	<40%
0	7	2	6	0	-7	-6	5	6	6	0	1.125245	1.131092	0.005847	0.52%	<5%
1	4	0	3	0	-5	-8	0	7	8	7	0.978369	0.821801	0.156568	16.00%	<20%
6	5	0	6	0	-6	-6	0	7	5	7	1.164996	1.250369	0.085373	7.33%	<10%
0	9	0	4	0	-1	-3	0	0	0	0	0.969663	1.082056	0.112393	11.59%	<20%
0	0	0	6	0	0	0	0	2	0	6	1.328561	1.111472	0.217089	16.34%	<20%
3	7	0	8	0	-8	0	7	3	9	5	1.043179	1.005964	0.037215	3.57%	<5%
-1	0	0	4	9	-9	-8	9	8	9	5	1.052867	0.943938	0.108929	10.35%	<20%
0	8	0	2	0	-8	-3	4	6	8	4	0.996052	0.846087	0.149964	15.06%	<20%
-3	6	0	0	7	6	-6	2	5	0	0	0.888772	0.859608	0.029164	3.28%	<5%
0	0	0	3	0	-2	-3	6	3	2	4	1.079605	1.174973	0.095368	8.83%	<10%
-3	6	1	4	0	7	0	0	0	6	7	1.054221	1.242430	0.188209	17.85%	<20%
-4	4	0	4	5	4	-5	0	0	5	5	1.285535	0.972628	0.312906	24.34%	<30%
-5	0	0	6	8	-5	-7	0	5	0	0	1.305718	1.109011	0.196707	15.07%	<20%
-7	8	0	8	0	9	0	0	7	7	7	1.028650	1.311584	0.282935	27.51%	<30%
0	0	0	7	0	-7	-8	7	7	7	0	1.274672	1.104608	0.170064	13.34%	<20%
-7	-7	0	0	0	0	0	0	0	0	0	1.106335	1.252829	0.146494	13.24%	<20%
5	5	0	5	0	-5	-5	5	5	5	9	1.192307	1.148891	0.043416	3.64%	<5%
3	6	2	5	8	-8	-8	0	4	3	6	1.220556	0.982247	0.238309	19.53%	<20%
3	4	0	4	3	5	-4	3	5	5	4	1.023675	1.285099	0.261424	25.54%	<30%
5	5	0	5	5	5	-5	0	5	6	9	1.229027	1.382245	0.153217	12.47%	<20%
8	5	0	0	0	7	0	7	0	8	0	1.186835	1.144493	0.042342	3.57%	<5%
5	7	0	4	0	-6	0	5	4	0	0	1.001729	1.016666	0.014937	1.49%	<5%
2	0	4	0	0	-6	-1	6	7	0	6	0.916423	0.879559	0.036864	4.02%	<5%
0	5	0	5	0	5	0	0	0	0	3	1.284137	1.191853	0.092284	7.19%	<10%
-5	5	0	4	0	9	-7	4	7	7	0	1.035143	1.061578	0.026435	2.55%	<5%
0	0	0	7	0	0	-6	7	8	0	0	1.173720	1.030394	0.143326	12.21%	<20%
-5	7	0	0	4	6	-7	7	7	0	0	1.312517	0.880819	0.431698	32.89%	<40%
-3	0	0	4	0	0	-4	3	5	0	0	1.156041	1.045546	0.110495	9.56%	<10%
-6	6	5	7	0	0	-7	3	4	7	7	1.287918	1.081892	0.206026	16.00%	<20%
-7	7	0	5	0	0	-8	0	8	0	6	1.064118	0.961262	0.102856	9.67%	<10%
0	4	0	5	0	-5	-6	5	6	6	5	1.584635	0.878319	0.706316	44.57%	<50%
1	4	0	8	0	7	-6	4	6	1	6	0.770373	1.113701	0.343328	44.57%	<50%
5	6	0	6	0	6	-5	2	4	0	4	1.163046	0.779281	0.383765	33.00%	<40%
3	0	0	5	3	-5	-6	7	6	6	6	1.389298	0.942062	0.447235	32.19%	<40%
1	1	0	8	0	7	0	5	7	0	0	1.127022	1.352362	0.225340	19.99%	<20%
0	8	0	7	8	-8	-8	6	7	2	7	1.282579	0.935457	0.347121	27.06%	<30%
0	0	7	0	0	-6	-8	9	7	0	9	1.142855	1.146073	0.003218	0.28%	<5%
0	5	0	8	2	7	-7	8	4	7	5	1.186141	1.249313	0.063172	5.33%	<10%
0	5	0	2	0	0	0	0	3	3	0	1.073710	1.041081	0.032630	3.04%	<5%
0	0	0	2	0	-3	0	2	4	0	3	1.355184	0.864860	0.490324	36.18%	<40%
8	7	0	0	9	2	-9	0	7	5	9	1.168717	1.245192	0.076475	6.54%	<10%
0	0	0	0	0	0	-5	1	8	8	8	1.099976	0.986232	0.113744	10.34%	<20%
-5	5	0	7	0	-9	-7	7	3	6	8	1.917797	1.064571	0.853226	44.49%	<50%
0	8	0	0	0	7	-9	8	0	8	9	1.213469	1.283614	0.070144	5.78%	<10%
4	8	0	2	0	-6	-7	0	3	0	5	1.752394	1.475649	0.276745	15.79%	<20%
7	7	0	7	0	7	0	7	0	0	0	1.008732	1.255989	0.247257	24.51%	<30%
0	5	0	0	0	5	-5	5	0	5	0	1.220824	1.357981	0.137157	11.24%	<20%
-5	0	0	0	0	0	-9	8	0	8	0	0.657630	1.018924	0.361294	54.94%	>50%
5	9	0	8	0	6	0	0	0	9	0	1.037609	1.161160	0.123552	11.91%	<20%
5	9	0	0	0	9	-5	5	9	3	0	1.087667	1.103214	0.015548	1.43%	<5%
6	9	0	6	5	-9	9	4	0	5	6	1.181638	1.279979	0.098341	8.32%	<10%
3	9	0	2	0	9	-3	9	5	0	5	1.137524	1.199730	0.062206	5.47%	<10%
5	9	0	5	0	-5	-9	0	0	5	5	1.897357	1.504052	0.393305	20.73%	<30%
0	-3	0	0	0	0	-3	0	0	0	4	0.973546	0.766896	0.206650	21.23%	<30%
0	0	0	0	0	9	-9	9	9	0	0	1.242834	1.104770	0.138064	11.11%	<20%
7	6	0	5	0	8	-5	5	0	0	0	1.268724	1.356898	0.088174	6.95%	<10%
-1	-1	0	0	0	-7	0	1	7	0	4	0.990704	1.075545	0.084841	8.56%	<10%
5	8	0	0	0	5	-5	0	0	0	0	0.956714	1.286422	0.329707	34.46%	<40%
3	7	0	5	0	3	0	0	0	0	0	1.822236	1.594565	0.227672	12.49%	<20%



# ANEXOS- Resultados Experimentais

x 0	x 1	x 2	x 3	x 4	x 5	x 6	x 7	x 8	x 9	x 10	y	y'	error	error(%)	Cat
7	7	0	6	0	0	-6	0	0	0	6	1.484693	1.414321	0.070372	4.74%	<5%
-6	6	3	4	0	3	0	4	4	0	0	1.051615	1.227029	0.175415	16.68%	<20%
-7	8	5	5	7	7	-7	0	0	6	6	1.002269	0.997934	0.004335	0.43%	<5%
-8	6	3	8	5	0	-8	5	3	7	5	0.957998	1.027474	0.069476	7.25%	<10%
-2	7	0	4	0	-6	-4	0	0	2	4	1.032286	0.965760	0.066527	6.45%	<10%
0	0	0	5	4	-3	-1	0	2	0	0	1.199813	1.101085	0.098728	8.23%	<10%
-1	6	0	2	9	-9	-4	6	6	4	2	1.634246	0.997176	0.637070	38.98%	<40%
0	0	0	5	0	-7	0	8	7	0	8	0.994100	1.063515	0.069415	6.98%	<10%
0	0	0	0	0	-7	3	4	1	0	0	1.225837	1.228578	0.002741	0.22%	<5%
-6	-1	9	2	0	8	-6	0	0	8	9	0.764718	1.037012	0.272293	35.61%	<40%
0	9	0	8	0	6	-8	7	5	7	6	1.368309	1.266686	0.101624	7.43%	<10%
0	0	6	0	8	6	-5	8	6	6	5	0.655136	0.857474	0.202338	30.89%	<40%
6	7	0	0	0	-8	0	8	6	0	0	1.118042	1.153251	0.035210	3.15%	<5%
0	0	0	5	5	-5	0	0	0	5	9	1.022409	0.950368	0.072041	7.05%	<10%
3	5	0	1	3	6	-4	1	0	0	2	0.795546	1.188426	0.392880	49.39%	<50%
-3	0	0	0	0	2	0	2	6	0	0	1.076272	0.555656	0.520616	48.37%	<50%
0	-6	0	0	0	0	-5	0	0	0	4	1.237125	0.903474	0.333651	26.97%	<30%
1	-2	0	5	3	-3	-3	1	0	5	3	1.010494	1.099708	0.089214	8.83%	<10%
4	6	4	6	5	8	-6	0	2	0	2	1.114784	1.121810	0.007026	0.63%	<5%
8	8	0	7	0	8	7	7	5	0	5	1.070174	1.033268	0.036906	3.45%	<5%
7	7	0	6	0	-6	-6	6	6	6	6	1.153149	1.932387	0.779238	67.58%	>50%
0	0	5	3	0	-6	3	0	6	3	4	1.117351	0.648632	0.468720	41.95%	<50%
1	6	0	1	0	7	-8	2	8	0	6	1.237102	1.277282	0.040179	3.25%	<5%
0	8	0	0	0	7	-7	0	8	0	0	0.791686	0.990634	0.198947	25.13%	<30%
5	7	0	5	4	-4	0	8	8	5	7	1.117515	1.185396	0.067881	6.07%	<10%
-5	6	2	7	1	-7	0	0	6	7	7	1.018175	1.227899	0.209724	20.60%	<30%
2	2	0	4	0	5	3	5	8	6	0	1.032881	0.991957	0.040924	3.96%	<5%
5	8	0	5	0	0	0	0	0	0	5	1.519736	1.601754	0.082018	5.40%	<10%
-3	-5	2	3	3	-5	-5	5	5	1	3	0.915255	0.888666	0.026589	2.91%	<5%
-2	0	0	2	0	6	-3	0	0	0	0	1.140544	1.347519	0.206975	18.15%	<20%
0	7	6	0	5	-5	-5	3	0	3	6	1.039601	1.234799	0.195198	18.78%	<20%
5	5	0	0	4	7	-5	4	2	0	4	1.600406	1.079719	0.520687	32.54%	<40%
6	7	0	3	0	7	0	0	7	2	8	0.957344	1.143018	0.185674	19.40%	<20%
4	5	7	7	5	5	-5	2	2	6	3	1.016712	1.083995	0.067282	6.62%	<10%
-3	3	0	1	0	-5	-4	0	4	3	4	1.070813	1.185107	0.114294	10.67%	<20%
-5	9	0	7	0	0	-9	0	9	0	9	1.259282	1.104791	0.154492	12.27%	<20%
6	7	0	3	0	-7	-7	6	2	0	0	1.068530	1.238428	0.169898	15.90%	<20%
-4	0	0	7	0	-7	-8	7	6	4	7	1.149480	1.236895	0.087415	7.61%	<10%
5	5	0	0	0	0	-4	3	0	0	0	1.121155	1.317180	0.196025	17.48%	<20%
6	7	0	8	0	7	-9	0	7	7	7	1.372882	1.141602	0.231280	16.85%	<20%
9	0	5	6	8	-6	-8	1	7	0	9	1.094185	1.256078	0.161892	14.80%	<20%
-7	6	0	1	3	4	-6	7	5	0	5	1.295015	0.871767	0.423248	32.68%	<40%
2	3	0	3	0	5	-4	0	4	0	0	1.561452	1.004075	0.557377	35.70%	<40%
0	7	0	4	0	6	0	3	0	0	0	1.791574	1.261668	0.529906	29.58%	<30%
4	4	0	1	0	7	0	0	3	0	0	0.960456	1.324289	0.363833	37.88%	<40%

Tabela A-36: Resultados previsão através RNA (Net Console) Conjunto Treino 2014 e Conjunto Teste 2015

## A.3.2 Redes Neurais R

### R Dados 2013

### Modelo Estratégico 2013

Dados 2013												Modelo Estratégico 2013															
x_0	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_10	y	RPropm	P	RPropp	P	SAG	P	RPropAvg	P	AVG6	P	RPropmQ	P	RPropmQ	P	SAGQ	P
3	7	0	5	0	7	-6	7	7	4	2	1.059	1.056	P	1.064	P	1.059	P	1.060	P	1.104	P	1.059	P	1.102	P	1.147	P
0	0	5	0	0	2	0	2	0	0	0	0.864	0.867	P	0.863	P	0.864	P	0.857	P	0.866	P	0.862	P	0.864	P	0.863	P
-3	0	0	5	8	-6	-3	0	0	0	6	1.273	1.271	P	1.270	P	1.272	P	1.271	P	1.274	P	1.272	P	1.272	P	1.275	P
0	6	0	6	4	0	0	0	0	0	0	0.878	0.885	P	0.865	P	0.878	P	0.879	P	0.870	P	0.879	P	0.877	P	0.879	P
5	9	0	6	6	0	0	4	5	4	7	1.149	1.149	P	1.140	P	1.147	P	1.144	P	1.152	P	1.141	P	1.143	P	1.146	P
-3	3	3	1	3	3	3	3	3	2	0	0.659	0.652	P	0.659	P	0.655	P	0.658	P	0.673	P	0.658	P	0.662	P	0.657	P
-6	-5	0	6	0	0	0	7	0	6	5	1.016	1.018	P	1.016	P	1.012	P	1.013	P	1.001	P	1.014	P	1.017	P	1.013	P
7	7	0	6	0	0	-6	0	0	0	6	0.572	0.574	P	0.576	P	0.572	P	0.569	P	0.572	P	0.597	P	0.571	P	0.575	P
2	0	0	4	4	-4	-1	0	0	1	3	0.974	0.980	P	0.967	P	0.981	P	0.972	P	0.967	P	0.975	P	0.975	P	0.975	P
0	6	0	5	0	-6	-3	0	6	4	4	1.023	1.018	P	1.016	P	1.004	P	1.026	P	1.031	P	0.997	P	1.020	P	1.030	P
2	4	0	3	0	0	0	3	4	0	0	0.986	0.978	P	0.985	P	0.982	P	0.985	P	0.983	P	0.987	P	0.987	P	0.979	P
0	2	0	0	0	-3	0	0	0	0	0	1.153	1.133	P	1.091	P	1.153	P	1.146	P	1.138	P	1.151	P	1.152	P	1.151	P
-7	5	8	1	5	5	-4	0	0	2	2	1.036	1.039	P	1.035	P	1.036	P	1.039	P	1.037	P	1.036	P	1.032	P	1.036	P
-4	-3	2	3	9	-3	-6	7	3	3	6	1.161	1.167	P	1.152	P	1.159	P	1.168	P	1.160	P	1.162	P	1.162	P	1.160	P
-1	-1	2	0	0	-1	-1	0	0	2	2	0.731	0.728	P	0.718	P	0.727	P	0.770	P	0.755	P	0.729	P	0.732	P	0.730	P
-4	-5	4	4	0	4	-4	0	4	0	0	0.926	0.927	P	0.921	P	0.926	P	0.927	P	0.924	P	0.925	P	0.929	P	0.925	P
6	7	0	5	4	5	-6	6	2	6	3	1.140	1.138	P	1.135	P	1.142	P	1.134	P	1.163	P	1.140	P	1.165	P	1.135	P
-8	7	0	0	0	5	0	2	7	0	0	0.721	0.719	P	0.723	P	0.721	P	0.723	P	0.720	P	0.719	P	0.721	P	0.711	P
-2	-1	6	4	2	-5	-7	0	3	3	4	1.065	1.065	P	1.062	P	1.060	P	1.065	P	1.073	P	1.064	P	1.079	P	1.066	P
0	5	4	0	6	-9	-9	9	0	0	0	0.759	0.758	P	0.751	P	0.760	P	0.757	P	0.758	P	0.761	P	0.759	P	0.761	P
0	0	0	0	5	0	-3	0	2	0	0	0.704	0.704	P	0.698	P	0.702	P	0.690	P	0.720	P	0.705	P	0.703	P	0.700	P
0	2	0	2	0	3	3	0	2	0	0	1.294	1.289	P	1.291	P	1.293	P	1.288	P	1.292	P	1.294	P	1.287	P	1.294	P
-1	6	0	2	9	-9	-3	5	6	3	2	1.176	1.175	P	1.182	P	1.177	P	1.177	P	1.177	P	1.172	P	1.174	P	1.168	P
0	5	0	4	3	-5	0	5	0	0	0	0.925	0.932	P	0.912	P	0.921	P	0.927	P	0.922	P	0.924	P	0.926	P	0.920	P
3	6	1	3	3	6	0	7	3	4	4	1.855	1.853	P	1.855	P	1.854	P	1.857	P	1.842	P	1.852	P	1.853	P	1.844	P
-6	-1	9	2	0	-6	-6	0	0	8	9	1.046	1.044	P	1.040	P	1.044	P	1.044	P	1.015	P	1.047	P	1.042	P	1.046	P
0	5	0	3	0	5	-4	3	4	0	5	1.206	1.211	P	1.209	P	1.206	P	1.219	P	1.203	P	1.207	P	1.197	P	1.203	P
0	4	0	4	0	-5	0	5	4	0	5	1.194	1.199	P	1.170	P	1.179	P	1.162	P	1.171	P	1.193	P	1.188	P	1.193	P
-2	-3	6	0	0	0	-7	2	0	0	5	1.042	1.046	P	1.042	P	1.041	P	1.048	P	1.041	P	1.041	P	1.039	P	1.041	P
2	6	0	0	0	-8	0	8	6	0	0	0.898	0.905	P	0.918	P	0.898	P	0.897	P	0.912	P	0.897	P	0.895	P	0.900	P
0	7	0	0	2	-5	-2	0	0	7	0	1.343	1.346	P	1.339	P	1.341	P	1.339	P	1.338	P	1.338	P	1.339	P	1.345	P
6	2	9	0	0	0	-1	6	3	0	2	1.007	1.007	P	1.013	P	1.006	P	1.009	P	1.004	P	1.005	P	1.006	P	1.006	P
-3	-3	0	5	4	-6	4	8	4	1	6	1.241	1.243	P	1.261	P	1.244	P	1.242	P	1.241	P	1.241	P	1.239	P	1.238	P

## ANEXOS- Resultados Experimentais

Dados 2013											Modelo Estratégico 2013																	
x <sub>0</sub>	x <sub>1</sub>	x <sub>2</sub>	x <sub>3</sub>	x <sub>4</sub>	x <sub>5</sub>	x <sub>6</sub>	x <sub>7</sub>	x <sub>8</sub>	x <sub>9</sub>	x <sub>10</sub>	y	RPropm		RPropp		SAG		RPropAvg		AVG6		RPropmQ		RPropmQ		SAGQ		
-1	0	5	0	9	0	2	1	0	0	0	1.061	1.057	P	1.060		P	1.060	P	1.065	P	1.059	P	1.060	P	1.059	P	1.059	P
4	7	0	4	0	-8	-4	0	0	0	4	1.876	1.874	P	1.884		P	1.876	P	1.877	P	1.874	P	1.878	P	1.875	P	1.876	P
-9	0	9	5	5	-5	0	0	0	0	5	0.825	0.825	P	0.826		P	0.824	P	0.830	P	0.841	P	0.821	P	0.816	P	0.827	P
-8	-6	1	8	5	0	0	7	0	8	7	0.743	0.742	P	0.738		P	0.746	P	0.741	P	0.760	P	0.741	P	0.752	P	0.756	P
-5	0	1	0	0	0	2	0	0	0	0	0.757	0.756	P	0.752		P	0.755	P	0.751	P	0.753	P	0.757	P	0.756	P	0.756	P
6	0	5	0	0	-5	-5	6	0	0	5	1.366	1.369	P	1.368		P	1.368	P	1.371	P	1.368	P	1.365	P	1.364	P	1.367	P
1	3	0	0	0	-4	-5	4	4	0	5	0.987	0.968	P	1.027		P	0.987	P	1.003	P	0.986	P	0.979	P	0.974	P	0.982	P
2	3	0	0	4	-4	-4	0	0	3	0	2.958	0.958	P	0.958		P	0.960	P	0.962	P	0.947	P	0.957	P	0.958	P	0.959	P
0	0	0	0	0	0	0	2	3	0	4	0.993	0.988	P	0.985		P	0.988	P	1.002	P	0.981	P	0.994	P	0.997	P	0.990	P
0	7	1	3	5	-5	7	3	4	3	1	0.988	0.983	P	0.992		P	0.989	P	0.988	P	0.992	P	0.989	P	0.985	P	0.992	P
-4	6	0	6	0	-6	-6	6	5	6	6	1.065	1.060	P	1.037		P	1.065	P	1.063	P	1.049	P	1.043	P	1.024	P	1.056	P
1	0	0	1	0	0	-1	1	0	1	1	1.131	1.114	P	1.062		P	1.107	P	1.107	P	1.101	P	1.130	P	1.128	P	1.133	P
-5	0	0	0	0	0	-5	6	0	0	5	1.011	1.012	P	1.023		P	1.010	P	0.979	P	1.019	P	1.010	P	1.011	P	1.010	P
-2	-1	0	0	2	3	0	0	0	0	4	0.952	0.952	P	0.943		P	0.951	P	0.951	P	0.944	P	0.951	P	0.951	P	0.952	P
0	0	0	4	0	-3	-6	0	5	7	0	1.080	1.090	P	1.082		P	1.078	P	1.102	P	1.077	P	1.081	P	1.075	P	1.078	P
4	7	0	0	0	0	0	4	0	0	0	0.767	0.754	P	0.749		P	0.767	P	0.770	P	0.773	P	0.766	P	0.764	P	0.774	P
0	5	0	4	0	-4	-4	4	4	4	4	0.881	0.939	P	0.918		P	0.927	P	0.925	P	0.951	P	0.970	P	0.984	P	0.900	P
-1	0	8	2	0	-6	4	0	5	6	1	0.894	0.895	P	0.897		P	0.890	P	0.893	P	0.888	P	0.893	P	0.894	P	0.896	P
1	4	0	7	0	6	-8	2	8	0	0	1.066	1.066	P	1.066		P	1.064	P	1.070	P	1.068	P	1.068	P	1.051	P	1.063	P
1	3	0	3	0	-3	-6	0	5	5	5	1.179	1.146	P	1.187		P	1.181	P	1.172	P	1.175	P	1.181	P	1.180	P	1.176	P
2	4	0	7	0	-5	-3	0	2	0	4	0.979	0.976	P	0.982		P	0.985	P	0.976	P	0.990	P	0.985	P	0.977	P	0.979	P
0	0	5	3	0	0	-2	0	3	4	0	1.188	1.191	P	1.188		P	1.188	P	1.182	P	1.194	P	1.189	P	1.186	P	1.186	P
5	5	0	4	3	-4	-4	5	2	0	5	0.734	0.728	P	0.737		P	0.727	P	0.729	P	0.728	P	0.728	P	0.739	P	0.740	P
-1	0	0	1	9	-9	-7	9	7	0	5	1.165	1.167	P	1.174		P	1.167	P	1.165	P	1.169	P	1.165	P	1.168	P	1.165	P
4	7	0	0	0	4	4	0	0	0	2	0.845	0.842	P	0.843		P	0.845	P	0.847	P	0.842	P	0.844	P	0.846	P	0.847	P
-2	3	0	0	6	9	-9	7	5	0	0	1.051	1.047	P	1.051		P	1.050	P	1.051	P	1.049	P	1.051	P	1.055	P	1.047	P
-4	4	0	4	3	2	-3	0	0	3	3	0.925	0.925	P	0.935		P	0.927	P	0.910	P	0.916	P	0.928	P	0.917	P	0.918	P
0	0	0	5	0	-5	-6	5	5	5	5	1.188	1.189	P	1.188		P	1.187	P	1.160	P	1.151	P	1.189	P	1.198	P	1.192	P
3	7	0	9	0	2	-8	6	3	3	4	1.198	1.192	P	1.202		P	1.196	P	1.208	P	1.155	P	1.195	P	1.166	P	1.186	P
0	-1	0	1	0	-1	-1	1	1	1	1	1.023	0.932	P	0.987		P	0.946	P	0.934	P	0.959	P	0.922	P	0.905	P	0.922	P
0	2	6	6	5	-2	0	0	4	4	5	1.139	1.138	P	1.142		P	1.140	P	1.136	P	1.130	P	1.139	P	1.139	P	1.137	P
7	6	0	4	0	8	3	5	8	5	0	1.275	1.280	P	1.274		P	1.273	P	1.280	P	1.267	P	1.273	P	1.265	P	1.272	P
-8	5	0	0	0	3	-4	6	0	0	8	0.833	0.833	P	0.827		P	0.832	P	0.830	P	0.827	P	0.832	P	0.834	P	0.835	P
3	6	2	4	5	-8	-8	4	4	3	6	1.163	1.160	P	1.162		P	1.164	P	1.170	P	1.165	P	1.164	P	1.152	P	1.165	P
-3	6	0	4	0	-3	-4	4	7	0	4	1.184	1.192	P	1.126		P	1.182	P	1.162	P	1.173	P	1.176	P	1.185	P	1.184	P
0	3	0	4	0	0	0	0	0	0	2	0.806	0.807	P	0.828		P	0.831	P	0.814	P	0.845	P	0.807	P	0.805	P	0.805	P
-3	-3	0	0	0	0	0	0	0	0	0	1.229	1.221	P	1.223		P	1.229	P	1.230	P	1.233	P	1.230	P	1.229	P	1.230	P
-3	-4	2	3	3	-5	-5	5	5	1	3	1.307	1.301	P	1.308		P	1.308	P	1.274	P	1.302	P	1.307	P	1.305	P	1.308	P
0	0	0	0	4	-1	0	0	3	0	0	1.190	1.189	P	1.215		P	1.194	P	1.192	P	1.196	P	1.194	P	1.193	P	1.188	P
3	1	0	0	0	-4	4	5	2	0	0	0.906	0.904	P	0.929		P	0.912	P	0.906	P	0.901	P	0.906	P	0.906	P	0.905	P
6	5	0	0	0	3	4	5	2	0	7	1.067	1.064	P	1.069		P	1.066	P	1.065	P	1.070	P	1.068	P	1.068	P	1.068	P
-5	0	5	7	0	0	-7	3	4	4	7	1.184	1.185	P	1.189		P	1.187	P	1.179	P	1.167	P	1.184	P	1.187	P	1.181	P
-8	0	0	0	0	0	0	0	0	0	0	1.021	1.029	P	1.033		P	1.023	P	1.025	P	1.026	P	1.020	P	1.019	P	1.020	P
-7	7	0	3	0	0	-7	0	8	0	6	1.095	1.104	P	1.080		P	1.095	P	1.112	P	1.105	P	1.098	P	1.104	P	1.079	P
0	0	0	0	5	0	0	0	0	0	0	0.608	0.609	P	0.600		P	0.605	P	0.615	P	0.605	P	0.608	P	0.606	P	0.608	P
-5	9	0	5	0	0	-7	0	7	0	9	1.102	1.100	P	1.100		P	1.101	P	1.120	P	1.084	P	1.099	P	1.105	P	1.118	P
5	6	0	6	0	6	-5	2	4	0	4	1.268	1.265	P	1.271		P	1.267	P	1.255	P	1.250	P	1.264	P	1.276	P	1.254	P
1	1	0	6	0	7	0	0	0	0	0	1.137	1.138	P	1.138		P	1.136	P	1.137	P	1.133	P	1.136	P	1.139	P	1.139	P
0	5	0	0	0	0	-5	3	0	0	0	0.686	0.696	P	0.712		P	0.685	P	0.689	P	0.686	P	0.690	P	0.684	P	0.688	P
0	6	0	0	0	7	-9	8	0	6	9	1.171	1.173	P	1.171		P	1.169	P	1.168	P	1.184	P	1.171	P	1.169	P	1.170	P
-5	5	0	4	4	5	-5	6	6	6	5	0.936	0.939	P	0.933		P	0.936	P	0.941	P	0.942	P	0.932	P	0.925	P	0.935	P
0	0	0	9	0	-9	0	9	0	0	0	0.792	0.791	P	0.794		P	0.792	P	0.791	P	0.794	P	0.791	P	0.789	P	0.795	P
2	5	0	4	0	2	-6	0	5	5	5	1.885	1.884	P	1.889		P	1.885	P	1.890	P	1.884	P	1.878	P	1.881	P	1.885	P
7	7	0	7	0	-7	0	0	0	0	0	1.530	1.531	P	1.529		P	1.530	P	1.530	P	1.530	P	1.529	P	1.530	P	1.533	P
0	0	0	0	0	1	0	0	0	0	8	1.106	1.110	P	1.114		P	1.109	P	1.112	P	1.105	P	1.105	P	1.106	P	1.107	P
0	0	0	0	0	8	-9	8	9	0	0	1.222	1.225	P	1.224		P	1.223	P	1.222	P	1.214	P	1.222	P	1.217	P	1.212	P
2	2	0	0	0	0	0	0	2	0	0	1.023	1.045	P	1.057		P	1.029	P	1.039	P	1.032	P	1.024	P	1.021	P	1.017	P
0	5	0	0	0	0	0	0	0	0	0	1.097	0.843	T	0.852		T	0.964	T	0.930	T	0.958	T	0.800	T	0.894	T	0.906	T
-5	7	0	6	5	6	-7	8	0	0	7	1.018	0.813	T	0.912		T	1.120	T	0.835	T	0.897	T	1.224	T	1.004	T	0.788	T
-5	0	9	0	0	0	0	5	0	0	0	0.848	0.830																

# ANEXOS- Resultados Experimentais

Dados 2013												Modelo Estratégico 2013															
x_0	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_10	y	RPropm		RPropp		SAG		RPropAvg		AVG6		RPropmQ		RPropQ		SAGQ	
-1	-1	0	0	0	-7	0	1	7	0	4	1.014	1.258	T	1.159	T	1.279	T	1.213	T	1.224	T	1.038	T	1.216	T	1.398	T

Tabela A-37: Redes Neurais R - Resultados Dados 2013. Modelo Estratégico ME13 (R)

## Modelo Estratégico 2013 – Conjunto Teste 2014

Dados 2013											Modelo Estratégico 2013 - Coni. Teste 2014																	
x <sub>0</sub>	x <sub>1</sub>	x <sub>2</sub>	x <sub>3</sub>	x <sub>4</sub>	x <sub>5</sub>	x <sub>6</sub>	x <sub>7</sub>	x <sub>8</sub>	x <sub>9</sub>	x <sub>10</sub>	y	RPropm	RProp	SAG	RPropAvg	AVG6	RPropmQ	RPropQ	SAGQ									
0	7	0	5	0	7	-6	7	7	4	2	1.059	1.058	P	1.059	P	1.080	P	1.055	P	1.085	P	1.062	P	1.057	P	1.057	P	
0	0	5	0	0	7	0	2	0	0	0	0.864	0.862	P	0.864	P	0.870	P	0.866	P	0.862	P	0.865	P	0.864	P	0.864	P	
-3	0	0	5	8	-6	-3	0	0	0	6	1.273	1.275	P	1.272	P	1.271	P	1.272	P	1.277	P	1.271	P	1.271	P	1.272	P	
0	6	0	6	4	0	0	0	0	0	0	0.878	0.886	P	0.877	P	0.881	P	0.863	P	0.877	P	0.876	P	0.882	P	0.881	P	
5	9	0	6	6	0	0	4	5	4	7	1.149	1.150	P	1.145	P	1.144	P	1.150	P	1.149	P	1.145	P	1.146	P	1.151	P	
-3	3	3	1	3	3	3	3	2	0	0	0.659	0.661	P	0.660	P	0.658	P	0.659	P	0.661	P	0.661	P	0.661	P	0.660	P	
-6	-5	0	6	0	0	0	7	0	6	5	1.016	1.016	P	1.014	P	1.008	P	1.021	P	1.016	P	1.015	P	1.018	P	1.019	P	
7	7	0	6	0	0	-6	0	0	0	6	0.572	0.574	P	0.573	P	0.568	P	0.573	P	0.572	P	0.570	P	0.573	P	0.573	P	
2	0	0	4	4	-4	-1	0	0	1	3	0.974	0.984	P	0.974	P	0.988	P	0.964	P	0.970	P	0.978	P	0.977	P	0.976	P	
0	6	0	5	0	-6	-3	0	6	4	4	1.023	1.021	P	1.016	P	0.985	P	1.015	P	1.021	P	1.021	P	1.011	P	1.023	P	
2	4	0	3	0	0	0	3	4	0	0	0.986	0.976	P	0.989	P	0.985	P	0.991	P	1.004	P	0.986	P	0.984	P	0.988	P	
0	2	0	0	0	0	-3	0	0	0	0	1.153	1.146	P	1.154	P	1.160	P	1.159	P	1.130	P	1.154	P	1.151	P	1.154	P	
-7	-5	8	1	5	-5	-4	0	0	2	2	1.036	1.037	P	1.037	P	1.038	P	1.034	P	1.038	P	1.027	P	1.035	P	1.033	P	
-4	-3	2	3	9	-3	-6	7	3	3	6	1.161	1.162	P	1.145	P	1.166	P	1.161	P	1.167	P	1.174	P	1.164	P	1.163	P	
-1	-1	2	0	0	-1	-1	0	0	2	2	0.731	0.731	P	0.731	P	0.725	P	0.732	P	0.768	P	0.727	P	0.730	P	0.735	P	
-4	-5	4	4	0	-4	0	0	4	0	0	0.926	0.929	P	0.926	P	0.931	P	0.926	P	0.923	P	0.927	P	0.929	P	0.927	P	
6	7	0	5	4	5	-6	6	2	6	3	1.140	1.142	P	1.141	P	1.154	P	1.144	P	1.129	P	1.134	P	1.140	P	1.144	P	
-8	7	0	0	5	0	2	7	0	0	0	0.721	0.719	P	0.722	P	0.714	P	0.719	P	0.722	P	0.722	P	0.719	P	0.718	P	
-2	-1	6	4	2	-5	-7	0	3	3	4	1.065	1.065	P	1.071	P	1.031	P	1.066	P	1.062	P	1.070	P	1.061	P	1.071	P	
0	5	4	0	6	-9	-9	9	0	0	0	0.759	0.761	P	0.760	P	0.758	P	0.760	P	0.759	P	0.758	P	0.760	P	0.762	P	
0	0	0	5	0	-3	0	2	0	0	0	0.704	0.716	P	0.701	P	0.713	P	0.711	P	0.703	P	0.703	P	0.706	P	0.705	P	
0	2	0	2	0	3	3	0	2	0	0	1.294	1.293	P	1.293	P	1.289	P	1.289	P	1.300	P	1.286	P	1.295	P	1.292	P	
-1	6	0	2	9	-3	5	6	3	2	1.176	1.177	P	1.174	P	1.173	P	1.172	P	1.175	P	1.161	P	1.179	P	1.167	P	1.167	P
0	5	0	4	3	-5	0	5	0	0	0	0.925	0.918	P	0.924	P	0.916	P	0.921	P	0.926	P	0.923	P	0.922	P	0.920	P	
3	6	1	3	3	6	0	7	3	4	4	1.855	1.858	P	1.856	P	1.851	P	1.857	P	1.841	P	1.858	P	1.853	P	1.854	P	
-6	-1	9	2	0	-6	-6	0	0	8	9	1.046	1.047	P	1.047	P	1.048	P	1.047	P	1.043	P	1.051	P	1.047	P	1.048	P	
0	5	0	3	0	5	-4	3	4	0	5	1.206	1.208	P	1.203	P	1.210	P	1.195	P	1.213	P	1.204	P	1.206	P	1.211	P	
0	4	0	4	0	-5	0	5	4	0	5	1.194	1.201	P	1.187	P	1.215	P	1.200	P	1.207	P	1.252	P	1.203	P	1.190	P	
-2	-3	6	0	0	0	-7	2	0	0	5	1.042	1.040	P	1.042	P	1.036	P	1.031	P	1.036	P	1.044	P	1.042	P	1.040	P	
2	6	0	0	0	-8	0	8	6	0	0	0.898	0.892	P	0.895	P	0.891	P	0.898	P	0.899	P	0.904	P	0.899	P	0.898	P	
0	7	0	0	2	-5	-2	0	0	7	0	1.343	1.342	P	1.341	P	1.344	P	1.343	P	1.343	P	1.346	P	1.339	P	1.342	P	
6	2	9	0	0	0	-1	6	3	0	2	1.007	1.003	P	1.009	P	1.013	P	1.010	P	1.005	P	1.004	P	1.005	P	1.006	P	
-3	-3	0	5	4	-6	4	8	4	1	6	1.241	1.242	P	1.243	P	1.234	P	1.238	P	1.240	P	1.269	P	1.238	P	1.244	P	
-1	0	5	0	9	0	2	1	0	0	0	1.061	1.059	P	1.060	P	1.061	P	1.063	P	1.063	P	1.059	P	1.060	P	1.063	P	
4	7	0	4	0	-8	-4	0	0	0	4	1.876	1.877	P	1.877	P	1.875	P	1.870	P	1.878	P	1.874	P	1.876	P	1.878	P	
-9	0	9	5	5	-5	0	0	5	9	0.825	0.824	P	0.826	P	0.829	P	0.829	P	0.822	P	0.825	P	0.824	P	0.826	P	0.826	P
-8	-6	1	8	5	0	0	7	0	8	7	0.743	0.744	P	0.744	P	0.745	P	0.741	P	0.743	P	0.742	P	0.747	P	0.742	P	
-5	0	1	0	0	0	2	0	0	0	0	0.757	0.761	P	0.759	P	0.750	P	0.756	P	0.759	P	0.757	P	0.757	P	0.756	P	
6	0	5	0	0	-5	-5	6	0	0	5	1.365	1.364	P	1.367	P	1.362	P	1.367	P	1.366	P	1.365	P	1.365	P	1.364	P	
1	3	0	0	0	4	-5	4	4	0	5	0.987	0.986	P	0.986	P	0.986	P	0.990	P	1.004	P	0.991	P	0.986	P	0.987	P	
2	3	0	0	4	-4	0	0	3	0	2	0.958	0.986	P	0.961	P	0.934	P	0.962	P	0.963	P	0.971	P	0.954	P	0.958	P	
0	0	0	0	0	0	0	2	3	0	4	0.993	0.962	P	0.986	P	0.985	P	1.001	P	0.997	P	0.982	P	0.994	P	0.995	P	
0	7	1	3	5	-5	7	3	4	3	1	0.988	0.987	P	0.988	P	0.989	P	0.992	P	0.985	P	0.983	P	0.987	P	0.989	P	
-4	6	0	6	0	-6	-6	6	5	6	6	1.065	1.064	P	1.065	P	1.068	P	1.051	P	1.036	P	1.029	P	1.018	P	1.016	P	
1	0	0	1	0	0	-1	1	0	1	1	1.131	1.091	P	1.143	P	1.031	P	1.067	P	1.113	P	1.135	P	1.133	P	1.133	P	
-5	0	0	0	0	0	-5	6	0	0	5	1.011	1.010	P	1.010	P	1.004	P	1.010	P	1.016	P	1.004	P	1.006	P	1.012	P	
-2	-1	0	0	2	3	0	0	0	0	4	0.952	0.952	P	0.953	P	0.957	P	0.949	P	0.950	P	0.954	P	0.952	P	0.950	P	
0	0	0	4	0	-3	-6	0	5	7	0	1.080	1.079	P	1.080	P	1.079	P	1.076	P	1.080	P	1.083	P	1.077	P	1.079	P	
4	7	0	0	0	0	0	4	0	0	0	0.767	0.769	P	0.771	P	0.770	P	0.768	P	0.765	P	0.767	P	0.769	P	0.767	P	
0	5	0	4	0	-4	-4	4	4	4	4	0.881	0.876	P	0.905	P	0.972	P	0.901	P	0.929	P	0.917	P	0.941	P	0.984	P	
-1	0	8	2	0	-6	4	0	5	6	1	0.894	0.898	P	0.892	P	0.894	P	0.892	P	0.892	P	0.899	P	0.897	P	0.893	P	
1	4	0	7	0	6	-8	2	8	0	0	1.066	1.066	P	1.066	P	1.051	P	1.065	P	1.071	P	1.070	P	1.070	P	1.065	P	
1	3	0	3	0	-3	-6	0	5	5	5	1.179	1.179	P	1.186	P	1.183	P	1.181	P	1.166	P	1.168	P	1.173	P	1.178	P	
2	4	0	7	0	-5	-3	0	2	0	4	0.979	0.984	P	0.979	P	1.057	P	0.979	P	0.979	P	0.984	P	0.975	P	0.975	P	
0	0	5	3	0	0	-2	0	3	4	0	1.188	1.191	P	1.195	P	1.193	P	1.196	P	1.182	P	1.190	P	1.192	P	1.188	P	
5	5	0	4	3	-4	-4	5	2	0	5	0.734	0.749	P	0.736	P	0.724	P	0.739	P	0.746	P	0.756	P	0.729	P	0.739	P	
-1	0	0	1	9	-9	-7	9	7	0	5	1.165																	

# ANEXOS- Resultados Experimentais

Dados 2013											Modelo Estratégico 2013 - Conj. Teste 2014																
x	x <sup>2</sup>	x <sup>3</sup>	x <sup>4</sup>	x <sup>5</sup>	x <sup>6</sup>	x <sup>7</sup>	x <sup>8</sup>	x <sup>9</sup>	x <sup>10</sup>	y	RPropm	P	RPropp	P	SAG	P	RPropAvg	P	AVG6	P	RPropmQ	P	RProppQ	P	SAGQ	P	
-5	7	0	6	5	6	-7	8	0	0	7	1.018	1.017	P	1.018	P	1.026	P	1.020	P	1.025	P	1.030	P	1.022	P	1.017	P
-5	0	9	0	0	0	0	5	0	0	0	0.848	0.842	P	0.848	P	0.842	P	0.847	P	0.848	P	0.848	P	0.849	P	0.849	P
0	0	0	0	0	0	0	0	0	5	8	0.952	0.947	P	0.952	P	0.954	P	0.950	P	0.954	P	0.954	P	0.954	P	0.954	P
7	5	3	0	0	8	-8	0	5	0	0	0.840	0.841	P	0.841	P	0.832	P	0.841	P	0.841	P	0.843	P	0.839	P	0.840	P
-2	-1	7	0	1	0	-4	3	3	1	7	0.997	0.995	P	0.997	P	0.987	P	0.999	P	1.008	P	0.989	P	0.992	P	1.000	P
1	3	0	7	0	1	0	0	2	0	0	1.165	1.157	P	1.160	P	1.170	P	1.142	P	1.152	P	1.159	P	1.165	P	1.166	P
0	0	0	2	1	0	3	2	2	0	3	0.999	1.007	P	1.015	P	1.017	P	1.001	P	0.996	P	0.995	P	1.002	P	0.997	P
0	0	2	0	1	1	5	2	5	7	9	0.962	0.963	P	0.962	P	0.964	P	0.959	P	0.962	P	0.962	P	0.960	P	0.959	P
2	5	0	3	5	-3	-3	0	2	0	2	1.096	1.068	P	1.096	P	1.053	P	1.096	P	1.059	P	1.094	P	1.078	P	1.103	P
0	3	0	2	0	-4	-3	4	3	0	7	1.602	1.599	P	1.603	P	1.597	P	1.593	P	1.561	P	1.555	P	1.593	P	1.602	P
0	9	0	6	0	-4	-7	9	0	0	0	1.189	1.190	P	1.188	P	1.193	P	1.188	P	1.163	P	1.171	P	1.190	P	1.177	P
-1	-2	2	5	7	-5	-4	5	6	5	7	1.211	1.201	P	1.213	P	1.217	P	1.215	P	1.193	P	1.247	P	1.213	P	1.211	P
-5	7	5	7	5	5	-4	0	0	0	2	1.240	1.242	P	1.243	P	1.242	P	1.241	P	1.231	P	1.247	P	1.242	P	1.242	P
-5	0	4	0	0	0	0	8	0	5	8	1.383	1.382	P	1.383	P	1.387	P	1.386	P	1.384	P	1.380	P	1.383	P	1.380	P
0	4	0	5	0	0	-2	0	0	0	5	0.966	0.952	P	0.968	P	0.914	P	0.946	P	0.960	P	0.965	P	0.967	P	0.966	P
1	4	2	0	0	8	2	8	8	0	8	0.817	0.820	P	0.816	P	0.817	P	0.816	P	0.817	P	0.830	P	0.817	P	0.819	P
-4	-2	4	2	4	-3	-5	5	4	0	4	1.103	1.112	P	1.105	P	1.144	P	1.121	P	1.145	P	1.142	P	1.142	P	1.128	P
-5	-5	9	0	0	2	-5	0	6	8	9	0.933	0.930	P	0.931	P	0.939	P	0.934	P	0.930	P	0.938	P	0.937	P	0.939	P
-9	9	5	5	0	0	0	0	0	0	6	1.893	1.893	P	1.891	P	1.898	P	1.893	P	1.893	P	1.893	P	1.890	P	1.891	P
-7	-5	0	3	0	-4	-3	0	4	3	0	1.086	1.083	P	1.086	P	1.078	P	1.085	P	1.088	P	1.090	P	1.087	P	1.087	P
2	2	0	3	0	3	-6	5	1	1	1	1.210	1.214	P	1.209	P	1.189	P	1.204	P	1.206	P	1.205	P	1.207	P	1.206	P
0	5	0	2	0	0	0	5	0	5	3	1.021	1.008	P	1.019	P	1.021	P	1.030	P	1.024	P	1.021	P	1.020	P	1.022	P
-5	0	0	5	7	-5	-5	0	5	0	0	0.893	0.893	P	0.893	P	0.894	P	0.896	P	0.895	P	0.897	P	0.892	P	0.895	P
1	2	0	2	2	-2	2	2	3	0	0	1.062	1.036	P	1.031	P	1.029	P	1.056	P	1.039	P	1.050	P	1.060	P	1.062	P
-6	-9	0	0	0	0	0	0	0	0	0	1.182	1.180	P	1.184	P	1.186	P	1.181	P	1.184	P	1.183	P	1.183	P	1.183	P
5	5	0	5	0	-5	-5	5	5	9	1.088	1.088	P	1.087	P	1.096	P	1.080	P	1.078	P	1.089	P	1.087	P	1.054	P	
3	4	0	4	3	5	-4	3	5	5	3	1.110	1.110	P	1.106	P	1.108	P	1.110	P	1.112	P	1.111	P	1.106	P	1.111	P
6	5	0	0	7	0	7	0	6	0	0	0.778	0.776	P	0.777	P	0.771	P	0.779	P	0.779	P	0.782	P	0.778	P	0.779	P
-4	0	1	0	0	-5	-1	3	3	0	3	1.018	1.016	P	1.019	P	0.992	P	1.011	P	1.010	P	1.022	P	1.021	P	1.025	P
0	0	0	7	0	0	-6	7	7	0	0	1.029	1.028	P	1.034	P	1.067	P	1.040	P	1.039	P	1.026	P	1.030	P	1.029	P
-4	7	0	7	0	4	0	0	3	3	4	1.278	1.282	P	1.278	P	1.273	P	1.281	P	1.279	P	1.266	P	1.278	P	1.274	P
0	3	0	1	0	0	-1	0	2	0	0	0.964	0.980	P	0.973	P	0.939	P	0.963	P	0.961	P	0.960	P	0.962	P	0.965	P
0	4	0	0	0	2	0	0	0	0	0	1.377	1.384	P	1.381	P	1.341	P	1.364	P	1.376	P	1.375	P	1.377	P	1.377	P
0	6	0	6	6	7	-4	3	5	1	6	1.259	1.254	P	1.263	P	1.264	P	1.255	P	1.263	P	1.233	P	1.264	P	1.259	P
0	0	7	0	0	-6	-6	5	3	0	7	1.083	1.085	P	1.082	P	1.060	P	1.088	P	1.080	P	1.083	P	1.085	P	1.080	P
4	8	0	5	9	-4	-5	4	5	0	5	0.773	0.771	P	0.776	P	0.774	P	0.773	P	0.801	P	0.788	P	0.793	P	0.771	P
-1	-1	0	0	0	-7	0	1	7	0	4	1.014	1.013	P	1.014	P	1.015	P	1.013	P	1.014	P	1.010	P	1.017	P	1.013	P

Tabela A-38: Redes Neurais R - Resultados Dados 2013. Modelo Estratégico ME13T14 (R)

## Modelo Estratégico Global

Dados 2013											Modelo Estratégico Global (2013-2014-2015)																	
x <sup>0</sup>	x <sup>1</sup>	x <sup>2</sup>	x <sup>3</sup>	x <sup>4</sup>	x <sup>5</sup>	x <sup>6</sup>	x <sup>7</sup>	x <sup>8</sup>	x <sup>9</sup>	x <sup>10</sup>	y	RPropm	P	RPropp	P	SAG	P	RPropAvg	P	AVG6	P	RPropmQ	T	RProppQ	T	SAGQ	T	
3	7	0	5	5	0	7	-6	7	7	4	2	1.059	1.055	P	1.057	P	1.058	P	1.061	P	1.064	P	1.656	T	1.145	T	0.973	T
0	0	5	0	0	0	2	0	2	0	0	0	0.864	0.864	P	0.866	P	0.866	P	0.865	P	0.865	P	0.864	T	0.865	P	0.864	P
-3	0	0	5	5	8	-6	-3	0	0	0	6	1.273	1.270	P	1.273	P	1.272	P	1.272	P	1.272	P	1.278	P	1.274	P	1.273	P
0	6	0	6	6	4	0	0	0	0	0	0	0.878	0.873	P	0.879	P	0.880	P	0.879	P	0.879	P	1.440	T	0.685	T	0.982	T
5	9	0	6	6	0	0	4	5	4	7	1.149	1.081	P	1.079	P	1.080	P	1.080	P	1.080	P	1.014	T	1.011	T	1.009	T	
-3	3	3	1	3	3	3	3	3	2	0	0	0.659	0.666	P	0.659	P	0.662	P	0.665	P	0.673	P	0.663	P	0.658	P	0.656	P
-6	-5	0	6	0	0	0	0	7	0	6	5	1.016	1.026	P	1.027	P	1.029	P	1.026	P	1.027	P	1.028	P	1.028	P	1.027	P
7	7	0	6	0	0	0	-6	0	0	0	6	0.572	1.030	P	1.031	P	1.028	P	1.029	P	1.028	P	1.484	T	1.484	T	1.485	T
2	0	0	4	4	4	-4	-1	0	0	1	3	0.974	0.975	P	0.972	P	0.970	P	0.971	P	0.975	P	0.974	P	0.976	P	0.974	P
0	6	0	5	0	-6	-3	0	6	4	4	1.023	1.016	P	1.024	P	1.018	P	1.028	P	1.021	P	1.025	P	1.022	P	1.024	P	
2	4	0	3	0	0	0	0	3	4	0	0	0.986	1.213	T	1.171	T	1.010	T	1.185	T	1.078	T	1.171	T	1.067	T	0.984	T
0	2	0	0	0	0	-3	0	0	0	0	0	1.153	1.150	P	1.152	P	1.154	P	1.161	P	1.150	P	1.153	P	1.152	P	1.152	P
-7	5	8	1	5	5	-4	0	0	2	2	2	1.036	1.035	P	1.036	P	1.036	P	1.036	P	1.036	P	1.035	P	1.037	P	1.037	P
-4	-3	2	3	9	-3	-6	7	3	3	6	1.161	1.168	P	1.163	P	1.160	P	1.163	P	1.137	P	1.124	T	0.838	T	1.022	T	
-1	-1	2	0	0	0	-1	-1	0	0	2	2	0.731	0.725	P	0.721	P	0.738	P	0.712	P	0.730	P	0.730	P	0.732	P	0.732	P
-4	-5	4	4	0	4	-4	0	4	0	0	0	0.926	0.929	P	0.926	P	0.927	P	0.923	P	0.926	P	0.928	P	0.925	P	0.927	P
6	7	0	5	4	5	-6	6	2	6	3	3	1.140	1.334	T	1.329	T	1.329	T	1.331	T	1.331	T	1.299	P	1.296	P	1.296	P
-8	7	0	0	5	0	2	7	0	0	0	0	0.721	0.722	P	0.719	P	0.720	P	0.720	P	0.723	P	0.948	T	0.844	T	0.997	T
-2	-1	6	4	2	-5	-7	0	3	3	4	1	1.065	1.007	P	1.073	P	0.739	T	1.047	T	0.873	T	1.066	P	1.068	P	1.065	P
0	5	4	0	6	-9	-9	9	0	0	0	0	0.759	0.761	P	0.759	P	0.759	P	0.761	P	0.759	P	0.762	P	0.759	P	0.758	P
0	0	0	0	5	0	-3	0	2	0	0	0	0.704	0.703	P	0.704	P	0.701	P	0.708	P	0.703	P	0.705	P	0.703	P	0.704	P
-1	6	0	2	2	0	3	3	0	2	0	0	1.294	1.296	P	1.294	P	1.294	P	1.297	P	1.296	P	1.293	P	1.294	P	1.293	P
0	5	0	4	3	-5	0	5	0	0	0	2	1.176	0.943	T	1.098	T	0.819	T	1.017	T	1.212	T	1.059	P	1.133	T	1.156	P
0	5	0	4	3	-5	0	5	0	0	0	0	0.925	0.984	P	0.983	P	0.983	P	0.982	P	0.983	P	0.928	P	0.924	P	0.927	P
3	6	1	3	3	6	0	7	3	4	4	4	1.855	1.217	T	1.213	T	1.065	T	1.219	T	1.180	T	1.220	T	1.376	T	1.198	T
-6	-1	9	2	0	-6	-6	0	0	8	9	1.046	1.088	P	1.086	P	1.087	P	1.086	P	1.086	P	1.085	P	1.087	P	1.086	P	
0	5	0	3	0	5	-4	3	4	0	5	5	1.206	1.093	T	1.173	T	0.982	T	1.135	T	1.046	T	0.962	T	1.014	T	0.949	T
0	4	0	4	0	-5	0	5	4	0	5	5	1.194	1.246	T	1.312	T	1.410	T	1.274	T	1.267	T	1.197	P	1.193	P	1.196	P
-2	-3	6	0	0	0	-7	2	0	0	5	5	1.042	1.041	P	1.042	P	1.042	P	1.042	P	1.043	P	1.042	P	1.042	P	1.042	P
2	6	0	0	0	-8	0	8	6	0	0	0	0.898	0.905	P	0.897	P	0.899	P	0.906	P	0.902	P	0.901	P	0.897	P	0.899	P
0	7	0	0	2	-5	-2	0	0	7	0	1	1.343	1.040	T	0.865	T	0.168	T	0.943	T	0.402	T	0.947	T	1.056	T	-0.002	T
6	2	9	0	0	0	-1	6	3	0	2	2	1.007	1.006	P	1.007	P	1.006	P	1.005	P	1.007	P	1.005	P	1.007	P	1.006	P
-3	-3	0	5	4	-6	4	8	4	1	6	1	1.241	1.242	P	1.241	P	1.240	P	1.242	P	1.246	P	1.242	P	1.241	P	1.241	P
-1	0	5	0	9	0	2	1	0	0	0	0	1.061	0.987	T	0.842	T	0.837	T	0.948	T	1.027	T	1.061	P	1.060	P	1.060	P
4	7	0	4	0	-8	-4	0	0	0	0	4	1.876	1.876	P	1.877	P	1.872	P	1.878	P	1.876	P	1.874	P	1.877	P	1.876	P
-9	0	9	5	5	-5	0	0	0	5	9	0	0.825	0.761	T	0.978	T	0.775	T	0.858	T	0.995	T	0.825	P	0.826	P	0.825	P
-8	-6	1	8	5	0	0	7	0	8	7	0	0.743	0.740	P	0.744	P	0.744	P	0.743	P	0.744	P	0.991	T	0.725	T	0.981	T
-5	0	1	0	0	0	2	0	0	0	0	0	0.757	0.755	P	0.758	P	0.760	P	0.759	P	0.757	P	1.109	T	0.948	T	1.479	T
6	5	0	0	0	-5	-5	6	0	5	5	1	1.366	1.166	P	1.367	P	1.368	P	1.364	P	1.367	P	1.364	P	1.364	P	1.367	P
0	3	0	4	0	-5	4	5	4	0	5	5	0.987	0.975	P	0.987	P	0.987	P	0.987	P	0.989	P	1.415	T	0.924	T	1.415	T
2	3	0	0	4	-4	0	3	0	2	0	2	0.958	1.142	P	0.921	T	1.304	T	1.049	T	0.552	T	0.980	P	0.981	P	0.980	P
0	0	0	0	0	0	0	2	3	0	4	4	0.993	0.966	P	0.991	P	0.985	P	0.970	P	0.994	P	0.992	T	1.589	T	0.813	T
0	7	1	3	5	-5	7	3	4	3	1	1	0.988	0.987	P	0.989	P	0.990	P	0.986	P	0.987	P	0.987	P	0.987	P	0.986	P
-4	6	0	6	0	-6	-6	6	5	6	6	6	1.065	1.062	P	1.067	P	1.033	P	1.073	P	1.066	P	1.070	P	1.067	P	1.069	P
1	0	0	1	0	0	-1	1	0	1	1	1	1.131	1.108	T	0.973	T	0.792	T	1.038	T	1.486	T	1.133	P	1.131	P	1.131	P
-5	0	0	0	0	0	-5	6	0	0	5	5	1.011	1.010	P	1.013	P	1.013	P	1.012	P	1.012	P	1.012	P	1.008	P	1.013	P
-2	-1	0	0	2	3	0	0	0	0	4	4	0.952	0.949	P	0.952	P	0.950	P	0.954	P	0.950	P	0.954	P	0.953	P	0.952	P
0	0	0	4	0	-3	-6	0	5	7	0	0	1.080	1.195	T	1.500	T	2.028	T	1.353	T	1.011	T	1.080	P	1.080	P	1.080	P
4	7	0	0	0	0	0	4	0	0	0	0	0.767	1.237	T	1.238	T	1.237	T	1.239	T	1.238	T	1.237	T	1.238	T	1.238	T
0	5	4	0	4	0	-4	-4	4	4	4	4	0.881	0.921	P	0.877	P	1.027	P	0.929	P	1.004	P	1.223	T	1.310	T	1.308	T
-1	0	8	2	0	-6	4	0	5	6	1	1	0.894	0.894	P	0.894	P	0.895	P	0.894	P	0.895	P	0.893	P	0.892	P	0.893	P
1	4	0	7	0	6	-8	2	8	0	0	0	1.066	0.994	T	1.172	T	0.999	T	1.088	T	0.936	T	1.066	P	1.064	P	1.065	P
1	3	0	3	0	-3	-6	0	5	5	5	5	1.179	1.176	P	1.180	P	1.161	P	1.175	P	1.169	P	1.183	P	1.182	P	1.179	P
2	4	0	7	0	-5	-3	0	2	0	4	4	0.979	0.975	P	0.984	P	0.978	P	0.988	P	0.979	P	1.136	T	1.483	T	1.343	T
0	0	5	3	0	0	-2	0	3	4	0	0	1.188	1.189	P	1.191	P	1.190	P	1.180	P	1.191	P	1.189	P	1.189	P	1.188	P
5	5	0	4	0	-4	-4	5	2	0	5	5	0.734	1.243	P	1.241	P	1.242	P	1.242	P	1.244	P	0.732	P	0.737	P	0.735	P
-1	0	0	0	9	-9	-7	0	0	0	5	1	1.165	1.161	P	1.167	P	1.163	P	1.164	P	1.170	P	1.174	P	1.164	P	1.166	P
0	0	0	0	0	0	0	0	0	0	2	2	0.844	0.891	T	1.618	T	1.427	T	1.280	T	0.983	T	0.845	T	0.845	T	0.845	T
-2	3	0	0	6	9	-9	7	5	0	0	0	1.051	1.052	P	1.050	P	1.051	P	1.052	P	1.051	P	1.056	P	1.053			

## ANEXOS- Resultados Experimentais

[illegible]

*Tabela A-39: Redes Neurais R - Resultados Dados 2013. Modelo Estratégico MEGlobal (R)*

*R Dados 2014*

## Modelo Estratégico 2014

Dados 2014												Modelo Estratégico 2014																
x_0	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_10	y	RPropm	P	RPropp	P	SAG	P	RPropAvg	P	AVG6	P	Rpropmq	P	Rpropq	P	SAGQ	P	
2	6	7	0	0	0	2	-3	0	0	0	0.929	0.916	P	0.933	P	0.929	P	0.929	P	0.926	P	0.929	P	0.930	P	0.928	P	
-1	0	0	0	6	8	-7	-6	0	0	5	7	0.918	0.913	P	0.918	P	0.919	P	0.917	P	0.919	P	0.922	P	0.916	P	0.919	P
0	6	0	6	6	9	0	0	0	0	0	1.144	1.150	P	1.142	P	1.143	P	1.141	P	1.141	P	1.145	P	1.144	P	1.145	P	
5	9	0	6	6	0	0	0	4	5	4	7	1.009	1.032	P	1.014	P	1.009	P	1.011	P	1.014	P	1.009	P	1.060	P	1.023	P
-5	0	2	0	0	0	0	-1	5	0	0	0	1.043	1.040	P	1.035	P	1.044	P	1.043	P	1.042	P	1.043	P	1.045	P	1.046	P
0	0	0	0	0	0	0	0	0	0	4	8	0.964	0.943	P	0.964	P	0.964	P	0.964	P	0.957	P	0.964	P	0.966	P	0.962	P
0	9	0	9	5	9	-9	0	0	6	0	8	1.250	1.253	P	1.250	P	1.248	P	1.249	P	1.240	P	1.246	P	1.249	P	1.241	P
7	8	3	0	0	0	8	-8	7	5	0	0	1.191	1.182	P	1.191	P	1.190	P	1.191	P	1.194	P	1.191	P	1.198	P	1.191	P
-6	-5	0	6	0	0	0	0	7	0	6	5	0.947	0.943	P	0.949	P	0.946	P	0.949	P	0.944	P	0.945	P	0.942	P	0.946	P
1	4	0	8	0	1	-3	0	4	0	0	0	1.084	1.044	P	1.079	P	1.085	P	1.085	P	1.085	P	1.085	P	1.084	P	1.084	P
2	3	0	2	9	4	-3	-4	0	0	0	4	1.204	1.197	P	1.203	P	1.207	P	1.204	P	1.206	P	1.203	P	1.199	P	1.206	P
0	4	3	5	0	0	-1	0	0	0	2	1.352	1.345	P	1.355	P	1.350	P	1.354	P	1.351	P	1.351	P	1.350	P	1.349	P	
0	2	0	0	6	3	-2	0	0	1	3	1.060	1.071	P	1.064	P	1.060	P	1.061	P	1.060	P	1.059	P	1.060	P	1.060	P	
1	1	3	0	2	3	3	4	2	6	6	0.653	0.653	P	0.655	P	0.654	P	0.642	P	0.651	P	0.653	P	0.647	P	0.657	P	
2	5	0	3	4	-4	-6	0	5	0	0	0	0.861	0.872	P	0.861	P	0.861	P	0.857	P	0.864	P	0.864	P	0.868	P	0.863	P
0	7	0	7	0	0	-8	-6	0	6	7	8	1.248	1.237	P	1.249	P	1.250	P	1.248	P	1.247	P	1.249	P	1.231	P	1.254	P
-3	-3	2	3	9	-3	-7	7	4	4	7	1.090	1.093	P	1.089	P	1.090	P	1.091	P	1.101	P	1.123	P	1.083	P	1.086	P	
0	3	0	2	0	4	-4	-4	4	3	0	8	1.412	1.403	P	1.365	P	1.406	P	1.411	P	1.389	P	1.402	P	1.414	P	1.414	P
6	7	0	5	4	5	-6	6	2	6	3	1.208	1.224	P	1.207	P	1.208	P	1.208	P	1.220	P	1.207	P	1.205	P	1.167	P	
-6	6	6	4	5	0	-7	5	3	5	5	1.081	1.079	P	1.090	P	1.081	P	1.073	P	1.072	P	1.073	P	1.074	P	1.050	P	
-8	7	0	0	0	0	-2	-2	2	7	0	0	1.248	1.244	P	1.247	P	1.248	P	1.243	P	1.248	P	1.247	P	1.244	P	1.248	P
0	0	0	5	0	-2	-1	0	1	0	0	0.858	0.867	P	0.859	P	0.857	P	0.856	P	0.859	P	0.858	P	0.857	P	0.860	P	

## ANEXOS- Resultados Experimentais

Dados 2014													Modelo Estratégico 2014												
x	y	z	u	v	w	x	y	z	u	v	w	x	RPropm	RPropp	SAG	RPropAvg	AVG6	RPropmQ	RPropmQ	RPropmQ	SAGQ				
-2	-1	2	4	2	-5	-7	0	3	3	6	0.951	0.951	P	0.951	P	0.952	P	0.975	P	0.971	P	0.948	P	0.952	P
-2	6	0	3	0	6	-8	7	7	0	0	1.013	1.008	P	1.025	P	1.013	P	1.009	P	1.018	P	1.014	P	1.022	P
0	5	4	0	6	-9	-9	9	0	0	0	1.235	1.229	P	1.235	P	1.236	P	1.233	P	1.245	P	1.236	P	1.237	P
0	9	0	6	0	-4	-7	7	9	0	0	0.991	0.978	P	0.991	P	0.986	P	1.000	P	0.978	P	0.991	P	0.986	P
-1	-2	2	5	7	-5	-4	5	6	5	7	1.156	1.160	P	1.155	P	1.158	P	1.156	P	1.151	P	1.141	P	1.161	P
0	2	0	2	0	3	3	0	0	0	0	0.981	0.982	P	0.981	P	0.980	P	0.979	P	0.986	P	0.981	P	0.982	P
-4	1	1	2	0	4	-4	3	4	4	5	0.884	0.942	P	0.886	P	0.893	P	0.928	P	0.897	P	0.887	P	0.892	P
-4	0	0	6	0	-7	0	8	7	0	8	1.039	1.039	P	1.037	P	1.038	P	1.038	P	1.044	P	1.041	P	1.031	P
0	5	0	4	3	-5	0	5	0	0	0	1.041	1.016	P	1.040	P	1.043	P	1.049	P	1.056	P	1.042	P	1.048	P
4	7	1	7	4	7	0	8	8	4	4	1.308	1.308	P	1.306	P	1.307	P	1.310	P	1.296	P	1.312	P	1.303	P
-6	-1	9	2	0	-6	-6	0	8	9	9	1.126	1.115	P	1.128	P	1.125	P	1.126	P	1.125	P	1.125	P	1.126	P
0	5	0	5	0	-6	0	5	5	0	5	1.206	1.206	P	1.216	P	1.208	P	1.210	P	1.194	P	1.204	P	1.206	P
-2	0	0	0	7	9	-7	2	6	2	8	1.051	1.051	P	1.053	P	1.051	P	1.051	P	1.049	P	1.053	P	1.048	P
-6	0	0	0	0	6	-5	0	6	0	6	0.617	0.618	P	0.625	P	0.617	P	0.617	P	0.618	P	0.617	P	0.621	P
-2	-4	6	0	0	0	-4	2	0	0	6	0.607	0.589	P	0.606	P	0.608	P	0.605	P	0.608	P	0.607	P	0.600	P
0	8	0	8	6	-6	-5	7	0	0	8	1.039	1.045	P	1.038	P	1.038	P	1.038	P	1.054	P	1.040	P	1.032	P
3	7	0	0	0	-8	0	8	6	0	0	1.050	1.053	P	1.052	P	1.054	P	1.049	P	1.056	P	1.052	P	1.049	P
0	7	0	2	2	-5	-3	0	3	7	0	0.861	0.857	P	0.867	P	0.860	P	0.857	P	0.867	P	0.864	P	0.867	P
-4	9	0	8	0	-9	-1	0	0	0	2	1.244	1.246	P	1.241	P	1.245	P	1.243	P	1.242	P	1.243	P	1.241	P
6	6	0	0	0	6	0	6	8	0	0	1.170	1.164	P	1.170	P	1.170	P	1.165	P	1.167	P	1.169	P	1.173	P
0	0	4	0	9	0	1	1	0	0	0	0.907	0.909	P	0.906	P	0.907	P	0.907	P	0.906	P	0.908	P	0.902	P
0	0	0	5	5	-5	0	0	0	5	9	0.952	0.943	P	0.949	P	0.950	P	0.951	P	0.955	P	0.949	P	0.940	P
-3	8	0	2	0	0	-6	0	0	0	7	1.209	1.215	P	1.215	P	1.213	P	1.209	P	1.217	P	1.209	P	1.215	P
1	4	2	0	0	8	2	8	8	0	8	1.076	1.080	P	1.076	P	1.075	P	1.075	P	1.081	P	1.076	P	1.074	P
0	7	0	0	6	-6	-7	0	4	0	6	1.259	1.262	P	1.261	P	1.258	P	1.260	P	1.237	P	1.260	P	1.260	P
-8	0	6	1	2	1	4	2	3	2	4	1.193	1.185	P	1.196	P	1.192	P	1.190	P	1.193	P	1.192	P	1.191	P
-5	-5	5	5	5	5	5	5	5	5	5	1.013	1.011	P	1.014	P	1.013	P	1.012	P	1.011	P	1.012	P	1.013	P
2	4	0	0	0	6	-4	1	0	0	2	1.292	1.293	P	1.294	P	1.294	P	1.293	P	1.289	P	1.292	P	1.292	P
0	8	0	5	0	0	-9	0	9	3	0	0.943	0.952	P	0.940	P	0.944	P	0.946	P	0.950	P	0.943	P	0.950	P
1	3	0	0	2	2	3	3	3	0	4	0.998	1.003	P	0.984	P	1.002	P	1.000	P	1.004	P	0.998	P	0.998	P
4	-5	5	6	6	5	0	5	6	6	6	1.749	1.746	P	1.749	P	1.749	P	1.748	P	1.753	P	1.747	P	1.744	P
0	-5	6	0	0	4	-6	0	7	6	6	0.999	0.992	P	1.000	P	0.999	P	0.998	P	0.994	P	0.999	P	1.000	P
-6	3	0	2	0	2	-4	0	0	1	2	0.966	0.970	P	0.974	P	0.965	P	0.969	P	0.959	P	0.964	P	0.975	P
0	7	1	3	6	-5	7	3	4	3	1	0.954	0.959	P	0.953	P	0.953	P	0.957	P	0.954	P	0.954	P	0.955	P
1	-1	0	1	0	0	-2	1	0	0	2	1.043	1.034	P	1.047	P	1.043	P	1.049	P	1.037	P	1.043	P	1.043	P
-7	9	8	9	0	0	0	0	0	0	6	0.731	0.734	P	0.736	P	0.731	P	0.731	P	0.734	P	0.731	P	0.731	P
-2	-2	2	6	9	-7	-8	3	5	7	4	1.168	1.161	P	1.163	P	1.168	P	1.144	P	1.144	P	1.141	P	1.173	P
-5	-3	5	0	6	-5	-5	6	7	7	2	0.906	0.936	P	0.908	P	0.902	P	0.904	P	0.929	P	0.916	P	0.909	P
4	7	0	0	0	0	0	4	0	0	0	1.238	1.236	P	1.240	P	1.237	P	1.234	P	1.240	P	1.237	P	1.238	P
7	6	0	5	0	-5	-5	5	5	5	5	1.963	1.966	P	1.955	P	1.962	P	1.962	P	1.949	P	1.964	P	1.965	P
-7	-5	0	4	0	-4	-3	0	4	4	0	1.069	1.067	P	1.066	P	1.069	P	1.068	P	1.064	P	1.070	P	1.067	P
1	5	0	1	0	7	-8	2	8	0	4	1.218	1.221	P	1.228	P	1.219	P	1.218	P	1.211	P	1.218	P	1.216	P
5	4	0	5	0	-6	-5	0	2	0	4	1.396	1.406	P	1.400	P	1.403	P	1.396	P	1.397	P	1.395	P	1.401	P
0	0	3	0	0	0	-3	0	3	2	0	0.863	0.871	P	0.848	P	0.865	P	0.866	P	0.869	P	0.862	P	0.868	P
6	5	1	5	0	6	0	0	5	0	6	1.502	1.494	P	1.498	P	1.502	P	1.501	P	1.499	P	1.500	P	1.501	P
0	8	0	0	0	7	-7	0	8	0	0	0.992	0.987	P	0.994	P	0.992	P	0.991	P	0.993	P	0.992	P	1.004	P
3	6	0	8	0	-4	0	7	8	7	4	1.056	1.078	P	1.059	P	1.056	P	1.060	P	1.055	P	1.057	P	1.051	P
0	0	0	0	0	-5	0	0	4	4	0.524	0.524	P	0.525	P	0.523	P	0.523	P	0.528	P	0.526	P	0.522	P	
5	8	0	4	0	-8	-1	8	6	7	4	0.984	0.986	P	0.982	P	0.985	P	0.983	P	0.978	P	0.982	P	0.991	P
-2	5	0	0	8	6	-3	7	5	0	0	1.151	1.152	P	1.151	P	1.153	P	1.150	P	1.153	P	1.150	P	1.156	P
-4	4	0	4	4	3	-4	0	0	4	4	0.966	0.987	P	0.967	P	0.961	P	0.978	P	0.990	P	0.967	P	0.966	P
0	0	0	6	0	-6	-7	6	6	0	0	1.077	1.076	P	1.079	P	1.079	P	1.077	P	1.076	P	1.078	P	1.080	P
-5	3	3	5	3	-5	-5	0	5	5	6	1.287	1.296	P	1.285	P	1.287	P	1.284	P	1.271	P	1.288	P	1.281	P
5	5	0	5	0	-5	-5	5	5	5	9	1.149	1.155	P	1.148	P	1.148	P	1.149	P	1.180	P	1.148	P	1.150	P
-6	5	0	5	0	-3	-4	3	3	2	5	1.140	1.136	P	1.151	P	1.135	P	1.135	P	1.153	P	1.142	P	1.153	P
7	6	0	4	0	6	3	5	8	5	0	1.173	1.169	P	1.175	P	1.172	P	1.170	P	1.172	P	1.172	P	1.172	P
3	4	0	4	3	5	-4	3	5	5	4	1.286	1.265	P	1.288	P	1.287	P	1.285	P	1.277	P	1.288	P	1.282	P
0	7	3	0	5	-5	-5	3	2	2	4	1.182	1.199	P	1.178	P	1.190	P	1.182	P	1.187	P	1.182	P	1.155	P
0	5	0	5	0	5	0	0	5	0	3	1.268	1.279	P	1.265	P	1.272	P	1.262	P	1.235	P	1.269	P	1.272	P
5	7	0	0	1	5	-7	8	8	2	0	1.088	1.117	P	1.089	P	1.087	P	1.103	P	1.091	P	1.088	P	1.087	P
1	2	0	2	3	-3	-3	3	0	1	2	1.261	1.260	P	1.277	P	1.242	P	1.256	P	1.218	P	1.261	P	1.262	P
4	6	0	2	0	6	0	0	4	0	6	1.035	1.038	P	1.033	P	1.033	P	1.034	P	1.050	P	1.037	P	1.033	P
-7	7	0	4	0	0	-8	0	8	0	6	0.950	0.959	P	0.950	P	0.951	P	0.951	P	0.983	P	0.949	P	0.963	P
-9	9	0	5	0	-9	-9	0	5	0	0	1.364	1.369	P	1.363	P	1.363	P	1.367	P	1.371	P	1.366	P	1.366	P
-3	3	0</																							

# ANEXOS- Resultados Experimentais

Dados 2014											Modelo Estratégico 2014																
x <sub>0</sub>	x <sub>1</sub>	x <sub>2</sub>	x <sub>3</sub>	x <sub>4</sub>	x <sub>5</sub>	x <sub>6</sub>	x <sub>7</sub>	x <sub>8</sub>	x <sub>9</sub>	x <sub>10</sub>	y	RPropm	RProp	SAG	RPropAvg	AVG6	RPropmQ	RPropQ	SAGQ								
-3	0	0	2	7	3	-5	5	4	5	6	1.107	1.123	T	1.080	T	0.845	T	1.132	T	1.067	T	1.109	T	1.109	T	1.078	T
2	4	0	5	0	5	-5	5	1	4	2	1.486	1.137	T	1.005	T	1.033	T	1.036	T	1.086	T	0.846	T	0.767	T	0.944	T
0	7	2	6	0	-7	-6	5	5	0	0	1.072	1.093	T	1.306	T	1.079	T	1.317	T	1.266	T	1.226	T	1.507	T	1.202	T
0	0	0	4	0	0	0	0	2	0	5	1.091	1.038	T	1.081	T	1.008	T	1.019	T	1.241	T	0.875	T	1.010	T	1.014	T
3	1	0	4	0	-4	-3	4	3	0	0	1.191	1.096	T	1.280	T	1.220	T	1.230	T	1.442	T	1.995	T	1.140	T	1.804	T
0	0	0	2	0	-1	-3	4	2	0	1	1.235	1.064	T	1.197	T	1.202	T	1.087	T	0.980	T	1.658	T	1.338	T	1.214	T
1	2	0	4	3	-3	-6	4	4	5	0	1.108	1.001	T	0.989	T	0.940	T	1.027	T	1.059	T	1.025	T	1.058	T	1.144	T
-6	3	8	1	6	0	-2	1	3	7	7	0.977	1.222	T	0.873	T	1.017	T	1.059	T	1.075	T	1.089	T	0.993	T	0.902	T
0	0	0	0	5	0	0	0	5	6	9	1.037	1.132	T	1.093	T	0.952	T	0.906	T	0.833	T	1.068	T	0.994	T	1.038	T
-6	-3	0	0	0	0	0	0	0	0	0	1.320	0.979	T	0.728	T	1.263	T	1.032	T	0.390	T	0.984	T	1.358	T	0.434	T
0	0	0	7	0	0	-6	7	6	0	0	0.977	1.055	T	1.156	T	0.863	T	1.074	T	0.810	T	1.284	T	0.991	T	1.065	T
-6	0	5	7	0	0	-7	3	4	4	7	1.237	0.953	T	1.095	T	0.934	T	0.924	T	0.985	T	1.041	T	1.104	T	1.092	T
1	3	0	7	0	6	-5	4	6	2	5	1.109	1.046	T	1.020	T	1.193	T	1.077	T	1.108	T	0.855	T	1.204	T	0.996	T
-4	0	0	4	1	-3	-4	4	2	1	4	1.525	1.070	T	1.277	T	1.172	T	1.091	T	1.107	T	1.217	T	1.202	T	1.219	T
0	0	0	5	0	-6	-7	7	5	0	9	1.216	1.410	T	1.350	T	1.336	T	1.551	T	1.337	T	1.501	T	1.468	T	1.317	T
5	6	0	1	0	0	4	0	0	0	0	1.328	1.016	T	1.632	T	1.329	T	1.168	T	1.393	T	2.041	T	0.701	T	1.233	T
0	5	9	0	0	5	-5	5	0	5	0	1.005	0.832	T	0.703	T	0.764	T	1.016	T	0.780	T	0.895	T	0.580	T	0.910	T
4	5	0	5	2	7	-7	8	3	5	7	1.318	1.105	T	0.971	T	1.120	T	0.876	T	1.200	T	1.000	T	1.194	T	0.962	T
-1	-3	0	4	0	-6	-6	0	0	4	5	1.544	0.803	T	1.245	T	0.931	T	0.917	T	0.896	T	0.646	T	0.956	T	0.830	T
-3	4	3	1	3	3	3	3	3	3	0	0.851	1.009	T	1.007	T	0.981	T	1.069	T	1.048	T	1.292	T	0.601	T	1.084	T
-2	0	0	0	3	0	-6	6	0	0	0	1.206	1.350	T	1.214	T	1.078	T	1.020	T	1.088	T	1.339	T	1.659	T	1.113	T
-2	0	0	0	0	0	-1	0	3	0	4	0.929	1.039	T	0.972	T	1.039	T	1.022	T	0.977	T	0.898	T	0.457	T	0.881	T
8	8	0	5	6	4	-5	7	4	0	0	1.113	1.108	T	1.487	T	1.035	T	1.184	T	1.007	T	1.231	T	0.960	T	1.214	T
-8	0	5	5	0	0	-4	6	7	7	8	1.015	0.956	T	1.048	T	1.054	T	1.028	T	1.024	T	0.964	T	1.159	T	1.109	T
-1	6	0	2	9	-9	-4	5	6	4	2	0.970	1.062	T	0.944	T	1.194	T	1.018	T	1.044	T	0.904	T	1.025	T	1.063	T
0	0	0	0	0	-5	2	3	1	0	0	1.072	0.764	T	0.604	T	0.215	T	0.724	T	0.821	T	0.791	T	1.076	T	1.187	T
0	0	4	7	0	-5	-8	3	4	3	4	1.346	1.148	T	1.355	T	1.043	T	1.206	T	1.301	T	1.202	T	1.744	T	1.137	T
5	6	0	7	0	0	5	2	0	7	1.114	1.327	T	1.066	T	1.060	T	1.131	T	1.179	T	0.866	T	0.887	T	1.354	T	
5	5	0	5	0	4	-2	8	5	0	5	1.164	1.049	T	0.948	T	1.117	T	0.933	T	0.956	T	0.895	T	1.170	T	0.957	T
0	0	0	0	0	0	0	0	4	9	1.152	0.932	T	0.986	T	0.964	T	0.971	T	0.984	T	0.991	T	0.991	T	0.959	T	
0	6	0	5	4	0	-5	0	7	0	5	1.065	1.062	T	1.155	T	1.080	T	1.101	T	1.089	T	0.980	T	1.141	T	1.248	T
2	3	0	0	4	-4	0	0	3	0	2	0.986	1.033	T	1.043	T	1.015	T	0.949	T	0.973	T	1.277	T	1.073	T	0.938	T
8	8	0	7	0	8	7	7	5	0	5	1.033	1.437	T	1.138	T	2.171	T	1.255	T	1.248	T	0.942	T	1.101	T	1.393	T
0	0	0	1	0	-5	-6	0	3	0	0	1.358	1.166	T	1.123	T	0.885	T	1.033	T	1.092	T	0.903	T	1.573	T	0.685	T
6	7	0	9	0	8	-9	0	7	0	7	1.051	0.795	T	0.940	T	0.791	T	0.847	T	0.944	T	0.873	T	1.195	T	1.014	T
0	4	0	4	0	-4	-7	0	5	7	6	0.896	1.036	T	0.956	T	0.986	T	1.094	T	1.044	T	0.974	T	1.163	T	1.003	T
5	5	0	4	3	-4	-4	5	2	0	5	1.749	1.342	T	1.296	T	1.346	T	1.082	T	1.366	T	1.628	T	1.314	T	1.412	T
0	0	0	2	9	-9	-8	9	8	0	5	0.961	1.381	T	0.799	T	1.287	T	1.119	T	1.152	T	1.137	T	1.218	T	1.026	T
4	7	0	2	2	-4	0	4	4	4	7	1.042	1.101	T	1.079	T	0.968	T	0.859	T	0.890	T	1.020	T	1.091	T	0.962	T
-5	0	0	5	8	-5	-7	0	5	0	0	1.056	1.107	T	0.915	T	0.936	T	0.901	T	1.028	T	0.997	T	1.112	T	1.010	T
0	-1	0	1	0	-1	-1	1	1	1	1	0.995	0.891	T	0.817	T	0.895	T	0.919	T	0.984	T	1.033	T	1.075	T	1.131	T
-4	-8	0	0	0	0	0	0	0	0	0	1.160	0.946	T	0.813	T	0.296	T	1.022	T	0.761	T	0.757	T	1.071	T	1.188	T
3	6	2	5	5	-8	-8	0	7	3	6	0.901	1.237	T	1.149	T	1.227	T	1.194	T	1.184	T	1.048	T	1.208	T	1.233	T
-1	1	1	0	7	-5	-3	0	7	8	8	1.090	1.125	T	1.080	T	0.995	T	0.887	T	0.840	T	1.046	T	1.081	T	1.008	T
-4	0	1	0	0	-6	-1	6	6	0	5	1.005	1.026	T	1.191	T	1.344	T	1.141	T	1.184	T	1.099	T	1.099	T	1.151	T
5	5	0	0	0	7	-5	4	6	6	0	0.904	1.121	T	1.155	T	1.160	T	1.128	T	1.151	T	1.116	T	1.061	T	1.120	T
-9	-3	7	3	7	-5	-6	0	4	0	4	1.168	1.138	T	1.153	T	1.024	T	0.938	T	1.081	T	1.038	T	1.223	T	1.031	T
-8	0	0	0	0	0	0	0	0	0	0	1.126	1.002	T	0.855	T	0.950	T	1.146	T	0.809	T	0.868	T	1.572	T	1.055	T
0	0	8	0	7	0	-6	6	0	5	7	1.070	0.986	T	0.963	T	0.879	T	0.963	T	0.738	T	0.938	T	1.045	T	0.880	T
1	7	0	6	1	-8	-7	4	8	3	8	0.726	1.260	T	1.145	T	1.222	T	1.294	T	1.238	T	1.258	T	1.204	T	1.347	T
-5	9	0	6	0	0	-8	0	8	0	9	1.129	0.917	T	1.108	T	1.032	T	1.052	T	0.999	T	1.007	T	1.015	T	1.062	T
-4	-8	0	0	0	-8	-5	7	9	0	8	0.943	0.983	T	1.050	T	1.221	T	1.054	T	1.053	T	1.268	T	1.021	T	0.899	T
1	1	0	7	0	7	0	0	0	0	0	1.682	1.010	T	0.976	T	0.302	T	0.811	T	0.640	T	0.518	T	0.767	T	1.059	T
0	5	0	8	6	7	-7	8	6	3	5	1.040	1.177	T	1.237	T	1.243	T	1.291	T	1.163	T	1.231	T	1.178	T	1.217	T
0	0	0	0	0	0	-5	1	1	8	8	1.074	1.037	T	0.953	T	1.068	T	1.062	T	0.767	T	0.776	T	0.947	T	0.602	T
1	5	0	5	0	7	-7	0	5	4	6	1.075	1.100	T	1.142	T	1.346	T	1.019	T	1.270	T	0.927	T	1.205	T	1.254	T
7	7	0	7	0	-7	0	0	0	0	0	1.161	1.314	T	1.919	T	1.203	T	1.342	T	1.319	T	2.106	T	1.224	T	1.332	T
-5	0	5	0	5	9	0	5	7	5	5	1.051	1.037	T	1.099	T	0.727	T	1.043	T	0.933	T	0.874	T	0.870	T	0.923	T
4	9	0	8	0	6	0	0	0	9	0	1.206	0.779	T	1.277	T	1.155	T	1.323	T	1.242	T	0.987	T	0.906	T	1.063	T
0	0	5	1	0	7	0	7	7	0	9																	



## ANEXOS- Resultados Experimentais

0	5	4	0	6	-9	-9	9	0	0	0	1.235	0.761	T	0.760	T	0.758	T	0.760	T	0.759	T	0.758	T	0.760	T	0.762	T
0	9	0	6	0	-4	-7	7	9	0	0	0.991	1.190	T	1.188	T	1.193	T	1.188	T	1.163	T	1.171	T	1.190	T	1.190	T
-1	-2	2	5	7	-5	-4	5	6	5	7	1.156	1.201	T	1.213	T	1.217	T	1.215	T	1.193	T	1.247	T	1.213	T	1.211	T
0	2	0	2	0	3	3	0	0	0	0	0.981	1.297	T	1.230	T	1.329	T	1.321	T	1.513	T	1.241	T	1.930	T	1.123	T
-4	1	1	2	0	4	-4	3	4	4	5	0.884	1.077	T	1.049	T	1.145	T	1.066	T	1.106	T	1.104	T	0.920	T	0.815	T
-4	0	0	6	0	-7	0	8	7	0	8	1.039	1.607	T	1.256	T	1.685	T	1.155	T	1.293	T	1.325	T	1.169	T	1.240	T
0	5	0	4	3	-5	0	5	0	0	0	1.041	0.918	T	0.924	T	0.916	T	0.921	T	0.926	T	0.923	T	0.922	T	0.920	T
4	7	1	7	4	7	0	8	8	4	4	1.308	2.132	T	1.332	T	1.795	T	1.673	T	1.517	T	1.597	T	1.704	T	1.557	T
-6	-1	9	2	0	-6	-6	0	0	8	9	1.326	1.047	T	1.047	T	1.048	T	1.047	T	1.043	T	1.051	T	1.047	T	1.048	T
0	5	0	5	0	0	0	5	5	0	5	1.206	1.181	T	1.149	T	1.227	T	1.109	T	1.157	T	1.095	T	1.167	T	1.131	T
2	0	0	0	7	9	-7	2	6	2	8	1.051	0.895	T	1.025	T	1.140	T	0.885	T	0.988	T	1.046	T	0.896	T	0.911	T
-6	0	0	0	0	6	-5	0	6	0	6	0.617	0.881	T	1.080	T	0.821	T	0.990	T	0.933	T	0.953	T	0.919	T	0.837	T
-2	-4	6	0	0	0	-4	2	0	0	6	0.607	0.871	T	1.064	T	1.103	T	0.972	T	0.935	T	0.989	T	0.975	T	0.921	T
0	8	0	8	6	-6	-5	7	0	0	8	1.039	1.103	T	0.943	T	1.083	T	0.918	T	0.967	T	1.016	T	0.982	T	0.971	T
3	7	0	0	0	-8	0	8	6	0	0	1.050	0.871	T	0.848	T	0.882	T	0.952	T	0.854	T	0.898	T	0.794	T	0.875	T
0	7	0	2	2	-5	-3	0	3	7	0	0.861	1.188	T	1.045	T	0.923	T	1.166	T	1.154	T	1.231	T	1.149	T	1.280	T
-4	9	0	8	0	-9	-1	0	0	0	2	1.244	2.582	T	1.124	T	1.579	T	1.182	T	1.537	T	1.140	T	1.174	T	1.129	T
6	6	0	0	0	6	0	6	8	0	0	1.170	0.728	T	1.026	T	0.971	T	1.001	T	1.041	T	0.606	T	0.928	T	0.845	T
0	0	4	0	9	0	1	1	0	0	0	0.907	1.026	T	1.009	T	1.049	T	1.020	T	1.049	T	0.970	T	1.174	T	0.905	T
0	0	0	5	-5	-5	0	0	5	9	0.952	0.973	T	1.172	T	1.244	T	1.002	T	0.903	T	1.159	T	1.106	T	1.355	T	
-3	8	0	2	0	0	-6	0	0	0	7	1.209	1.267	T	1.311	T	1.311	T	1.387	T	1.206	T	1.224	T	1.131	T	1.466	T
1	4	2	0	0	8	2	8	8	0	8	1.076	0.820	T	0.816	T	0.817	T	0.816	T	0.817	T	0.830	T	0.817	T	0.819	T
0	7	0	0	6	-6	-7	0	4	0	6	1.259	1.663	T	1.335	T	1.089	T	1.212	T	1.073	T	1.059	T	1.020	T	1.229	T
-8	0	6	1	2	1	4	2	3	2	4	1.013	0.730	T	0.667	T	0.826	T	0.758	T	0.773	T	0.673	T	0.853	T	0.657	T
-5	-5	5	5	5	5	5	5	5	5	5	1.013	0.479	T	0.954	T	0.894	T	0.803	T	0.716	T	0.715	T	1.002	T	0.614	T
2	4	0	0	0	0	0	2	1.292	1.961	T	1.292	1.961	T	1.188	T	0.809	T	1.318	T	1.075	T	1.081	T	0.836	T	1.001	T
0	8	0	0	0	-9	0	9	3	0	0.943	1.164	T	1.054	T	1.089	T	1.232	T	1.172	T	1.189	T	0.960	T	1.229	T	
1	3	0	0	2	2	3	3	3	0	4	0.998	1.021	T	0.948	T	0.799	T	0.922	T	0.984	T	1.104	T	1.002	T	1.078	T
4	-5	5	6	6	5	0	5	6	6	6	1.749	1.424	T	1.104	T	0.706	T	1.001	T	1.216	T	1.232	T	1.070	T	1.181	T
0	-5	6	0	0	4	-6	0	7	6	6	0.999	1.198	T	1.225	T	1.027	T	0.830	T	0.998	T	1.168	T	0.804	T	1.038	T
-6	-3	0	2	0	2	-4	0	0	1	2	0.966	0.933	T	1.014	T	0.944	T	1.107	T	0.949	T	1.074	T	1.079	T	0.898	T
0	7	1	3	6	-5	-7	3	4	3	1	0.954	0.975	T	0.980	T	1.040	T	0.998	T	1.053	T	0.987	T	0.981	T	0.986	T
-1	-1	0	1	0	0	-2	1	0	0	2	1.043	1.065	T	1.195	T	1.146	T	1.062	T	1.009	T	1.151	T	1.035	T	1.231	T
-7	9	8	9	0	0	0	0	0	0	6	0.731	1.946	T	1.973	T	1.850	T	1.884	T	1.895	T	1.534	T	1.700	T	1.833	T
-2	-2	2	6	9	-7	-8	3	5	7	4	1.168	1.102	T	0.895	T	1.141	T	1.110	T	1.109	T	1.254	T	1.146	T	1.057	T
-3	-5	0	0	6	-5	-5	6	7	7	2	0.906	1.067	T	1.146	T	1.066	T	1.426	T	1.135	T	1.198	T	0.947	T	1.195	T
4	7	0	0	0	0	0	4	0	0	0	1.238	0.769	T	0.771	T	0.770	T	0.768	T	0.765	T	0.767	T	0.769	T	0.767	T
7	6	0	5	0	-5	-5	5	5	5	5	1.963	0.845	T	0.979	T	0.977	T	1.024	T	1.031	T	0.852	T	1.107	T	1.068	T
-7	-5	0	4	0	-4	-3	0	4	4	0	1.069	1.038	T	1.042	T	1.057	T	1.064	T	1.069	T	1.075	T	1.062	T	1.052	T
1	5	0	1	0	7	-8	2	8	0	4	1.218	0.873	T	0.965	T	1.329	T	1.169	T	1.066	T	0.867	T	0.934	T	1.154	T
5	4	0	5	0	-6	-5	0	2	0	4	1.396	0.900	T	1.057	T	1.053	T	1.421	T	1.197	T	1.322	T	1.157	T	1.011	T
0	0	3	0	0	0	-3	0	3	2	0	0.863	1.024	T	0.827	T	0.882	T	0.979	T	1.205	T	0.936	T	0.966	T	1.264	T
6	5	1	5	0	6	0	0	5	0	6	1.502	1.474	T	1.436	T	1.109	T	1.626	T	1.390	T	1.287	T	1.864	T	1.462	T
8	8	0	7	0	7	-7	0	8	0	0	0.992	1.099	T	0.999	T	0.992	T	1.054	T	0.993	T	1.057	T	0.908	T	1.098	T
3	6	0	8	0	-4	0	7	8	7	4	1.056	1.282	T	1.107	T	1.118	T	0.881	T	1.002	T	0.909	T	0.914	T	0.956	T
0	0	0	0	0	-5	0	0	0	4	4	0.524	0.980	T	0.985	T	0.922	T	1.004	T	1.234	T	1.445	T	0.937	T	1.259	T
5	8	0	4	0	-8	-1	8	6	7	4	0.984	1.046	T	1.090	T	1.096	T	0.881	T	0.925	T	0.770	T	0.854	T	0.938	T
-2	5	0	0	8	6	-3	7	5	0	0	1.151	0.884	T	1.015	T	0.853	T	0.905	T	0.931	T	0.648	T	0.922	T	0.897	T
-4	4	0	4	4	3	-4	0	0	4	4	0.966	1.004	T	0.903	T	0.915	T	0.940	T	0.953	T	0.970	T	0.908	T	0.903	T
0	0	0	6	0	-6	-7	6	6	6	0	1.077	1.396	T	1.305	T	1.161	T	1.152	T	1.189	T	1.183	T	1.169	T	1.187	T
-5	-3	3	5	3	-5	-5	0	5	5	6	1.287	0.908	T	1.038	T	1.039	T	0.881	T	0.978	T	1.073	T	1.352	T	1.094	T
5	5	0	5	0	-5	-5	5	5	9	1.149	1.088	T	1.087	T	1.096	T	1.080	T	1.078	T	1.089	T	1.087	T	1.054	T	
-6	5	0	5	0	-3	-4	3	3	2	5	1.140	1.187	T	1.067	T	1.136	T	1.084	T	1.057	T	1.097	T	1.156	T	1.184	T
7	6	0	4	0	6	3	5	8	5	0	1.173	1.385	T	1.179	T	1.275	T	1.329	T	1.307	T	1.302	T	1.240	T	1.373	T
3	4	0	4	3	5	-4	3	5	5	4	1.286	1.137	T	1.134	T	1.149	T	1.114	T	1.175	T	1.163	T	1.262	T	1.200	T
0	7	3	0	5	-5	-5	3	2	2	4	1.182	1.094	T	1.063	T	0.889	T	1.014	T	0.996	T	1.137	T	0.978	T	1.079	T
0	5	0	5	0	5	0	0	5	0	3	1.268	1.194	T	1.258	T	1.315	T	1.177	T	1.323	T	1.312	T	1.260	T	1.417	T
5	7	0	0	1	5	-7	8	8	2	2	0.088	0.496	T	0.942	T	1.158	T	1.026	T	0.917	T	0.613	T	0.872	T	1.046	T
1	2	0	2	3	-3	-3	3	0	1	2	1.261	0.845	T	1.017	T	1.038	T	0.993	T	0.894	T	0.942	T	0.688	T	0.830	T
4	6	0	2	0	6	0	0	4	0	6	1.035	1.315	T	1.470	T	1.262	T	1.500	T	1.421	T	1.245	T	1.855	T	1.581	T
-7	7	0	4	0	0	-8	0	8	0	6	0.950	1.072	T	1.094	T	1.092	T	1.095	T	1.092	T	1.092	T	1.087	T	1.095	T
9	9	0	6	0	-9	0	0	5	0	5																	



# ANEXOS- Resultados Experimentais

8	8	0	5	6	4	-5	7	4	0	0	1.113	0.767	T	1.068	T	0.995	T	1.062	T	0.767	T	0.637	T	0.820	T	1.041	T
-8	0	5	5	0	0	-4	6	7	7	8	1.015	1.169	T	1.105	T	1.019	T	1.171	T	1.105	T	1.094	T	1.093	T	1.019	T
-1	6	0	2	9	-9	-4	5	6	4	2	0.970	1.173	T	1.150	T	1.158	T	1.162	T	1.164	T	1.157	T	1.141	T	1.171	T
0	0	0	0	0	-5	-2	3	1	0	0	1.072	0.982	T	0.927	T	0.901	T	0.883	T	1.424	T	1.094	T	1.032	T	0.732	T
0	0	4	7	0	-5	-8	3	4	3	4	1.346	1.114	T	1.125	T	1.204	T	1.143	T	1.138	T	1.245	T	1.093	T	1.123	T
5	6	0	7	0	0	0	5	2	0	7	1.114	0.973	T	0.776	T	1.289	T	1.136	T	0.909	T	0.725	T	1.090	T	1.134	T
5	5	0	5	0	4	-2	8	5	0	5	1.164	0.997	T	1.248	T	1.257	T	1.417	T	1.334	T	1.233	T	1.495	T	1.422	T
0	0	0	0	0	0	0	0	0	4	0	1.152	1.093	T	1.031	T	0.986	T	0.969	T	0.987	T	0.890	T	0.943	T	0.952	T
0	6	0	5	4	0	-5	0	7	0	5	1.065	1.063	T	1.212	T	1.185	T	1.240	T	1.108	T	1.076	T	1.174	T	1.161	T
2	3	0	0	4	-4	0	0	3	0	2	0.986	0.986	T	0.961	T	0.934	T	0.962	T	0.963	T	0.971	T	0.954	T	0.958	T
8	8	0	7	0	8	7	7	5	0	5	1.033	1.709	T	1.952	T	1.438	T	1.367	T	1.541	T	1.073	T	1.798	T	1.166	T
0	0	0	1	0	-5	-6	0	3	0	0	1.358	0.956	T	1.111	T	0.954	T	0.984	T	1.246	T	1.514	T	0.812	T	0.888	T
6	7	0	9	0	8	-9	0	7	0	7	1.051	1.167	T	1.131	T	1.553	T	1.474	T	1.151	T	1.241	T	1.590	T	1.311	T
0	4	0	4	0	-4	-7	0	5	7	6	0.896	1.298	T	1.142	T	1.257	T	1.071	T	1.130	T	1.141	T	1.090	T	1.102	T
5	5	0	4	3	-4	-4	5	2	0	5	1.749	0.749	T	0.736	T	0.724	T	0.739	T	0.746	T	0.756	T	0.729	T	0.739	T
0	0	0	2	9	-9	-8	9	8	0	5	0.961	1.194	T	1.073	T	1.102	T	1.167	T	1.151	T	1.133	T	1.133	T	1.166	T
4	7	0	2	2	-4	-0	4	4	4	7	1.042	0.996	T	1.104	T	1.109	T	1.076	T	1.051	T	1.020	T	1.072	T	1.077	T
-5	0	0	5	8	-5	-7	0	5	0	0	1.056	0.871	T	0.859	T	0.794	T	0.792	T	0.876	T	0.849	T	0.818	T	0.900	T
0	-1	0	1	0	-1	-1	1	1	1	1	0.995	0.971	T	0.920	T	0.935	T	0.968	T	0.947	T	0.918	T	0.924	T	0.929	T
-4	-8	0	0	0	0	0	0	0	0	0	1.160	1.179	T	1.232	T	1.214	T	1.241	T	1.173	T	1.201	T	1.172	T	1.156	T
3	6	2	5	5	-8	-8	0	7	3	6	0.901	1.047	T	1.278	T	1.095	T	1.038	T	1.160	T	1.155	T	1.142	T	1.148	T
-1	1	1	0	7	-5	-3	0	7	8	8	1.090	0.847	T	1.126	T	1.022	T	0.983	T	0.956	T	1.043	T	0.919	T	1.005	T
-4	0	1	0	0	-6	-1	6	6	0	5	1.005	1.244	T	1.113	T	1.194	T	1.188	T	1.103	T	1.111	T	1.007	T	0.989	T
5	5	0	0	0	7	-5	4	6	6	0	0.904	0.863	T	1.006	T	1.201	T	0.991	T	0.931	T	1.068	T	0.804	T	0.884	T
-9	-3	7	3	7	-5	-6	0	4	0	4	1.168	0.904	T	0.562	T	0.886	T	0.919	T	0.980	T	1.140	T	0.886	T	1.250	T
-8	0	0	0	0	0	0	0	0	0	0	1.126	1.019	T	1.021	T	1.025	T	1.022	T	1.022	T	1.022	T	1.021	T	1.021	T
0	0	8	0	7	0	-6	6	0	5	7	1.070	1.350	T	1.010	T	0.929	T	1.245	T	1.215	T	1.137	T	1.084	T	1.267	T
1	7	0	6	1	-8	-7	4	8	3	8	0.726	1.202	T	1.335	T	1.275	T	0.968	T	1.164	T	1.140	T	1.142	T	1.102	T
-5	9	0	6	0	0	-8	0	8	0	9	1.129	1.130	T	1.086	T	1.159	T	1.102	T	1.122	T	1.106	T	1.092	T	1.079	T
-4	-8	0	0	0	-8	-5	7	9	0	8	0.943	1.422	T	1.463	T	1.478	T	1.201	T	1.212	T	1.134	T	1.062	T	0.973	T
1	1	0	7	0	7	0	0	0	0	0	1.682	1.117	T	1.164	T	1.113	T	1.130	T	1.082	T	1.127	T	1.181	T	1.137	T
0	5	0	8	6	7	-7	8	6	3	5	1.040	1.025	T	1.026	T	1.097	T	1.168	T	1.020	T	1.014	T	0.988	T	1.068	T
0	0	0	0	0	0	-5	1	1	8	8	1.074	1.521	T	1.060	T	0.926	T	1.336	T	1.318	T	1.424	T	1.028	T	1.164	T
1	5	0	5	0	7	-7	0	5	4	6	1.075	1.992	T	1.646	T	1.894	T	1.581	T	1.510	T	1.458	T	1.520	T	1.418	T
7	7	0	7	0	-7	0	0	0	0	0	1.161	1.523	T	1.530	T	1.527	T	1.530	T	1.530	T	1.530	T	1.529	T	1.530	T
-5	0	5	0	5	9	0	5	7	5	5	1.051	0.312	T	0.896	T	0.815	T	0.666	T	0.817	T	0.855	T	0.853	T	0.643	T
4	9	0	8	0	6	0	0	0	9	0	1.206	1.564	T	2.003	T	1.645	T	1.153	T	1.409	T	1.430	T	0.996	T	1.676	T
0	0	5	1	0	7	0	7	7	0	9	1.086	0.952	T	0.696	T	1.101	T	0.764	T	1.022	T	1.026	T	0.848	T	1.103	T
5	9	0	0	0	9	-5	5	9	9	0	0.978	0.993	T	0.926	T	1.288	T	0.852	T	0.980	T	0.985	T	0.742	T	1.058	T
5	6	0	5	0	5	-5	5	0	0	0	1.365	1.196	T	1.238	T	1.216	T	1.089	T	1.002	T	0.986	T	0.805	T	0.898	T

Tabela A-41: Redes Neurais R - Resultados Dados 2014. Modelo Estratégico ME13T14 (R)

## Modelo Estratégico 2014 – Conjunto Teste 2015

Dados 2014											Modelo Estratégico 2014 - Coni. Teste 2015														
x <sub>0</sub>	x <sub>1</sub>	x <sub>2</sub>	x <sub>3</sub>	x <sub>4</sub>	x <sub>5</sub>	x <sub>6</sub>	x <sub>7</sub>	x <sub>8</sub>	x <sub>9</sub>	x <sub>10</sub>	y	RPropm	RPropp	SAG	RPropAvg	AVG6	RPropmQ	RProppQ	SAGQ						
2	6	7	0	0	2	-3	0	0	0	0	0.929	0.930	P	0.925	P	0.929	P	0.927	P	0.930	P	0.926	P	0.926	P
-1	0	0	6	8	-7	-6	0	0	5	7	0.918	0.917	P	0.916	P	0.918	P	0.921	P	0.919	P	0.917	P	0.915	P
0	6	0	6	9	0	0	0	0	0	0	1.144	1.144	P	1.142	P	1.145	P	1.142	P	1.143	P	1.143	P	1.145	P
5	9	0	6	6	0	0	4	5	4	7	1.009	1.011	P	1.011	P	1.008	P	1.006	P	1.026	P	1.012	P	1.040	P
-5	0	2	0	0	0	-1	5	0	0	0	1.043	1.042	P	1.027	P	1.043	P	1.047	P	1.044	P	1.043	P	1.042	P
0	0	0	0	0	0	0	0	0	4	8	0.964	0.960	P	0.998	P	0.995	P	0.993	P	0.973	P	0.972	P	0.963	P
0	9	0	9	5	9	-9	0	6	0	8	1.250	1.250	P	1.247	P	1.249	P	1.249	P	1.227	P	1.241	P	1.247	P
7	8	3	0	0	8	-8	7	5	0	0	1.191	1.189	P	1.188	P	1.190	P	1.191	P	1.187	P	1.194	P	1.193	P
-6	-5	0	6	0	0	0	7	0	6	5	0.947	0.946	P	0.947	P	0.947	P	0.947	P	0.950	P	0.947	P	0.946	P
1	4	0	8	0	1	-3	0	4	0	0	1.084	1.088	P	1.087	P	1.082	P	1.083	P	1.086	P	1.082	P	1.085	P
2	3	0	2	9	4	-3	4	0	0	4	1.204	1.206	P	1.207	P	1.203	P	1.200	P	1.200	P	1.203	P	1.204	P
0	4	3	5	0	0	-1	0	0	0	2	1.352	1.342	P	1.351	P	1.340	P	1.340	P	1.350	P	1.354	P	1.355	P
0	2	0	0	6	3	-2	0	0	1	3	1.060	1.059	P	1.051	P	1.061	P	1.056	P	1.069	P	1.058	P	1.063	P
1	1	3	0	2	3	3	4	2	6	6	0.653	0.652	P	0.657	P	0.651	P	0.654	P	0.652	P	0.655	P	0.657	P
2	5	0	3	4	-4	-6	0	5	0	0	0.861	0.858	P	0.870	P	0.867	P	0.861	P	0.856	P	0.867	P	0.861	P
0	7	0	7	0	-8	-6	0	6	7	8	1.248	1.248	P	1.249	P	1.249	P	1.250	P	1.235	P	1.237	P	1.228	P
-3	-3	2	3	9	-3	-7	7	4	4	7	1.090	1.088	P	1.094	P	1.099	P	1.094	P	1.109	P	1.103	P	1.089	P
0	3	0	2	0	-4	-4	4	3	0	8	1.412	1.429	P	1.397	P	1.412	P	1.412	P	1.393	P	1.416	P	1.361	P
6	7	0	5	4	5	-6	6	2	6	3	1.208	1.206	P	1.217	P	1.207	P	1.205	P	1.219	P	1.210	P	1.242	P
-6	6	6	4	5	0	-7	5	3	5	5	1.081	1.078	P	1.079	P	1.081	P	1.082	P	1.075	P	1.062	P	1.093	P
-8	7	0	0	0	6	-2	7	0	0	0	1.248	1.250	P	1.246	P	1.248	P	1.249	P	1.247	P	1.247	P	1.249	P
0	0	0	5	0	-2	-1	0	1	0	0	0.858	0.905	P	0.863	P	0.905	P	0.855	P	0.879	P	0.856	P	0.855	P
-2	-1	2	4	5	2	-5	-7	3	3	6	0.951	0.944	P	0.952	P	0.955	P	0.949	P	0.946	P	0.955	P	0.953	P
-2	6	0	3	0	6	-8	7	7	0	0	1.013	1.015	P	1.012	P	1.013	P	1.015	P	1.020	P	1.016	P	1.020	P
0	5	4	0	6	-9	-9	9	0	0	0	1.235	1.236	P	1.235	P	1.234	P	1.236	P	1.236	P	1.236	P	1.234	P
0	9	0	6	0	-4	-7	7	9	0	0	0.991	0.990	P	0.987	P	0.991	P	0.995	P	0.981	P	0.977	P	0.984	P
-1	-2	2	5	7	-5	-4	5	6	5	7	1.156	1.152	P	1.145	P	1.151	P	1.154	P	1.139	P	1.128	P	1.133	P
0	2	0	2	0	3	3	0	0	0	0	0.981	0.981	P	0.980	P	0.981	P	0.980	P	0.986	P	0.981	P	0.983	P
-4	1	1	2	0	4	-4	3	4	4	5	0.884	0.927	P	0.882	P	0.906	P	0.891	P	0.927	P	0.870	P	0.875	P
-4	0	0	6	0	-7	0	8	7	0	0	1.039	1.037	P	1.042	P	1.042	P	1.038	P	1.047	P	1.036	P	1.039	P
0	5	0	4	3	-5	0	5	0	0	0	1.041	1.040	P	1.051	P	1.042	P	1.041	P	1.046	P	1.042	P	1.046	P
4	7	1	7	4	7	0	8	8	4	4	1.308	1.308	P	1.313	P	1.310	P	1.308	P	1.294	P	1.306	P	1.276	P
-6	-1	9	2	0	-6	-6	0	0	8	9	1.126	1.125	P	1.129	P	1.125	P	1.127	P	1.125	P	1.126	P	1.128	P
0	5	0	5	0	-6	0	5	5	0	5	1.206	1.212	P	1.229	P	1.207	P	1.207	P	1.191	P	1.208	P	1.206	P
-2	0	0	0	7	9	-7	2	6	2	8	1.051	1.052	P	1.048	P	1.050	P	1.056	P	1.055	P	1.048	P	1.050	P
-6	0	0	0	0	6	-5	0	6	0	6	0.637	0.608	P	0.617	P	0.616	P	0.620	P	0.616	P	0.619	P	0.617	P
-2	-4	6	0	0	0	-4	2	0	0	6	0.607	0.609	P	0.604	P	0.609	P	0.606	P	0.609	P	0.606	P	0.630	P
0	0	6	6	-6	-5	-7	0	0	8	1.039	1.040	P	1.039	P	1.038	P	1.038	P	1.033	P	1.044	P	1.026	P	
3	0	4	0	0	0	0	3	6	0	0	1.045	1.048	P	1.045	P	1.045	P	1.049	P	1.054	P	1.054	P	1.040	P
7	0	7	0	2	-5	-3	0	7	0	0	0.861	0.861	P	0.855	P	0.863	P	0.864	P	0.861	P	0.865	P	0.860	P
-4	9	0	0	0	-9	-1	0	0	0	2	1.244	1.241	P	1.241	P	1.240	P	1.242	P	1.242	P	1.244	P	1.247	P
6	6	0	0	0	6	0	6	8	0	0	1.170	1.172	P	1.179	P	1.170	P	1.170	P	1.172	P	1.169	P	1.167	P
0	0	4	0	9	0	1	1	0	0	0	0.907	0.909	P	0.904	P	0.906	P	0.907	P	0.906	P	0.906	P	0.904	P
0	0	0	5	5	-5	0	0	0	5	9	0.952	0.952	P	0.953	P	0.956	P	0.949	P	0.954	P	0.954	P	0.948	P
-3	8	0	2	0	0	-6	0	0	0	7	1.209	1.216	P	1.208	P	1.209	P	1.207	P	1.213	P	1.211	P	1.208	P
1	4	2	0	0	8	2	8	8	0	8	1.076	1.075	P	1.079	P	1.076	P	1.078	P	1.081	P	1.071	P	1.071	P
0	7	0	0	6	-6	-7	0	4	0	6	1.259	1.258	P	1.261	P	1.258	P	1.260	P	1.256	P	1.257	P	1.261	P
-8	0	6	1	2	1	4	2	3	2	4	1.193	1.194	P	1.194	P	1.190	P	1.193	P	1.191	P	1.187	P	1.197	P
-5	-5	5	5	5	5	5	5	5	5	5	1.013	1.010	P	1.011	P	1.013	P	1.014	P	1.017	P	1.013	P	1.014	P
2	4	0	0	0	6	-4	1	0	0	2	1.292	1.295	P	1.291	P	1.290	P	1.292	P	1.294	P	1.292	P	1.295	P
0	8	0	5	0	0	-9	0	9	3	0	0.943	0.943	P	0.943	P	0.943	P	0.941	P	0.939	P	0.943	P	0.948	P
1	3	0	0	2	2	3	3	3	0	4	0.998	0.995	P	0.988	P	1.011	P	1.004	P	0.993	P	0.999	P	0.999	P
4	-5	5	6	6	5	0	5	6	6	6	1.749	1.748	P	1.751	P	1.749	P	1.748	P	1.752	P	1.747	P	1.748	P
0	-5	6	0	0	4	-6	0	7	6	6	0.999	0.995	P	1.001	P	0.997	P	1.000	P	0.998	P	0.998	P	0.993	P
-6	3	0	2	0	2	-4	0	0	1	2	0.966	0.943	P	0.987	P	0.966	P	0.967	P	0.961	P	0.964	P	0.963	P
0	7	3	3	6	0	-7	3	4	1	1	0.954	0.957	P	0.958	P	0.957	P	0.954	P	0.954	P	0.953	P	0.953	P
1	-1	0	1	0	0	0	0	0	0	2	1.044	1.037	P	1.052	P	1.048	P	1.039	P	1.048	P	1.044	P	1.041	P
-7	9	8	9	0	0	0	0	0	0	6	0.731	0.731	P	0.730	P	0.731	P	0.729	P	0.733	P	0.730	P	0.728	P
-2	-2	2	6	9	-7	-8	3	5	7	4	1.168	1.171	P	1.171	P	1.167	P	1.167	P	1.174	P	1.159	P	1.175	P

# ANEXOS- Resultados Experimentais

Dados 2014											Modelo Estratégico 2014 - Coni. Teste 2015										
0	1	2	3	4	5	6	7	8	9	10	y	RPropm	RPropp	SAG	RPropAvg	AVG6	RPropmQ	RPropmQ	SAGQ		
-5	-3	5	0	6	-5	-5	6	7	7	2	0.906	0.905	P	0.911	P	0.905	P	0.906	P	0.906	P
4	7	0	0	0	0	0	4	0	0	0	1.238	1.241	P	1.239	P	1.238	P	1.237	P	1.238	P
7	6	0	5	0	-5	-5	5	5	5	5	1.963	1.963	P	1.962	P	1.964	P	1.964	P	1.961	P
-7	-5	0	4	0	-4	-3	0	4	4	0	1.069	1.071	P	1.066	P	1.068	P	1.069	P	1.071	P
1	5	0	1	0	7	-8	2	8	0	4	1.218	1.211	P	1.212	P	1.217	P	1.217	P	1.221	P
5	4	0	5	0	-6	-5	0	2	0	4	1.396	1.393	P	1.393	P	1.395	P	1.394	P	1.402	P
0	0	3	0	0	0	-3	0	3	2	0	0.863	0.863	P	0.862	P	0.886	P	0.867	P	0.864	P
6	5	1	5	0	6	0	0	5	0	6	1.502	1.498	P	1.506	P	1.504	P	1.500	P	1.501	P
0	8	0	0	0	7	-7	0	8	0	0	0.992	0.992	P	0.993	P	0.992	P	0.994	P	0.987	P
3	6	0	8	0	-4	0	7	8	7	4	1.056	1.057	P	1.052	P	1.053	P	1.056	P	1.057	P
0	0	0	0	0	-5	0	0	4	4	4	0.524	0.526	P	0.522	P	0.527	P	0.524	P	0.525	P
5	8	0	4	0	-8	-1	8	6	7	4	0.984	0.986	P	0.992	P	0.982	P	0.983	P	0.986	P
-2	5	0	0	8	6	-3	7	5	0	0	1.151	1.151	P	1.154	P	1.150	P	1.150	P	1.164	P
-4	4	0	4	4	3	-4	0	0	4	4	0.966	0.959	P	0.970	P	0.965	P	0.965	P	0.979	P
0	0	0	6	0	-6	-7	6	6	6	0	1.077	1.075	P	1.077	P	1.076	P	1.077	P	1.077	P
-5	3	3	5	3	-5	0	0	5	5	6	1.287	1.281	P	1.286	P	1.288	P	1.286	P	1.290	P
5	5	0	5	0	-5	-5	5	5	5	9	1.149	1.148	P	1.154	P	1.149	P	1.145	P	1.156	P
-6	5	0	5	0	-3	-4	3	3	2	5	1.140	1.138	P	1.156	P	1.150	P	1.143	P	1.171	P
7	6	0	4	0	6	3	5	8	5	0	1.173	1.173	P	1.170	P	1.173	P	1.173	P	1.171	P
3	4	0	4	3	5	-4	3	5	5	4	1.285	1.287	P	1.293	P	1.284	P	1.289	P	1.261	P
0	7	3	0	5	-5	-5	3	2	2	4	1.182	1.182	P	1.186	P	1.185	P	1.176	P	1.187	P
0	5	0	5	0	5	0	0	5	0	3	1.268	1.266	P	1.248	P	1.267	P	1.239	P	1.263	P
5	7	0	0	1	5	-7	8	8	2	2	1.088	1.089	P	1.099	P	1.089	P	1.088	P	1.090	P
1	2	0	2	3	-3	-3	3	0	1	2	1.261	1.270	P	1.241	P	1.267	P	1.265	P	1.255	P
4	6	0	2	0	6	0	0	4	0	6	1.035	1.034	P	1.031	P	1.032	P	1.032	P	1.036	P
-7	7	0	4	0	0	-8	0	8	0	6	0.950	0.948	P	0.952	P	0.951	P	0.949	P	0.986	P
-9	9	0	5	0	-9	-9	0	5	0	0	1.364	1.365	P	1.366	P	1.365	P	1.363	P	1.363	P
3	3	0	1	0	0	-3	0	3	1	2	1.156	1.150	P	1.093	P	1.129	P	1.136	P	1.098	P
3	5	0	0	2	-9	7	9	5	9	9	1.039	1.042	P	1.040	P	1.042	P	1.043	P	1.034	P
5	3	6	5	5	5	0	6	6	6	7	0.990	0.989	P	0.989	P	0.993	P	0.989	P	0.991	P
0	4	0	4	0	7	-2	0	3	0	0	0.987	0.989	P	0.984	P	0.988	P	0.994	P	0.988	P
5	6	0	6	0	6	-5	2	4	0	4	0.781	0.780	P	0.781	P	0.779	P	0.779	P	0.784	P
-3	0	0	3	0	6	-6	5	2	2	6	1.380	1.385	P	1.381	P	1.380	P	1.379	P	1.385	P
-7	0	2	4	0	0	0	9	2	7	9	1.029	1.027	P	1.029	P	1.024	P	1.029	P	1.015	P
-5	4	0	2	0	0	0	0	3	2	0	0.972	0.979	P	0.976	P	0.982	P	0.975	P	0.987	P
-3	6	0	6	5	-4	8	0	0	6	0	1.131	1.132	P	1.129	P	1.129	P	1.128	P	1.129	P
1	5	0	1	0	-2	0	0	0	0	0	1.274	1.269	P	1.270	P	1.271	P	1.279	P	1.260	P
0	9	3	9	0	-5	9	0	5	8	6	1.758	1.758	P	1.765	P	1.759	P	1.759	P	1.759	P
0	0	0	0	0	1	0	0	0	8	0	0.909	0.909	P	0.914	P	0.913	P	0.908	P	0.912	P
6	5	0	9	0	6	-4	6	4	0	4	0.711	0.709	P	0.711	P	0.710	P	0.710	P	0.712	P
0	0	0	9	0	-9	-9	5	9	0	5	1.346	1.348	P	1.347	P	1.349	P	1.345	P	1.348	P
0	8	0	3	9	-5	-5	3	5	0	5	1.106	1.111	P	1.106	P	1.108	P	1.112	P	1.108	P
0	9	0	0	0	9	-3	9	5	0	2	1.491	1.488	P	1.492	P	1.491	P	1.491	P	1.490	P
0	0	8	9	0	-9	-9	5	5	0	0	1.763	1.763	P	1.763	P	1.762	P	1.764	P	1.766	P
-4	4	0	0	0	0	-3	0	4	4	4	1.152	1.147	P	1.129	P	1.136	P	1.143	P	1.133	P
-1	-1	0	0	0	-7	0	1	7	0	4	1.081	1.083	P	1.076	P	1.086	P	1.081	P	1.082	P
-6	0	0	5	0	5	0	0	6	0	7	1.043	1.037	P	1.052	P	1.044	P	1.041	P	1.043	P
-2	-1	7	0	1	0	-4	4	3	1	7	0.845	0.846	P	0.844	P	0.846	P	0.844	P	0.848	P
-5	-1	5	4	2	-6	-4	3	2	4	6	0.562	0.563	P	0.568	P	0.561	P	0.576	P	0.552	P
1	4	0	3	0	0	0	3	6	0	0	1.133	1.145	P	1.135	P	1.122	P	1.122	P	1.136	P
0	4	0	2	0	5	-4	0	2	3	0.966	0.965	P	0.968	P	0.963	P	0.967	P	0.962	P	
-5	7	5	7	5	6	-5	3	0	4	5	0.988	0.989	P	0.990	P	0.985	P	0.987	P	0.986	P
-6	6	0	0	8	0	-2	4	0	0	3	0.918	0.917	P	0.918	P	0.919	P	0.920	P	0.923	P
5	4	0	0	0	0	-1	6	6	0	5	0.865	0.866	P	0.862	P	0.864	P	0.863	P	0.867	P
6	0	5	0	0	-5	-6	6	0	0	5	0.893	0.893	P	0.892	P	0.892	P	0.892	P	0.892	P
-7	-2	6	0	0	-4	0	0	6	7	9	0.757	0.754	P	0.761	P	0.761	P	0.756	P	0.759	P
-7	0	8	7	7	0	0	0	0	0	3	1.145	1.145	P	1.137	P	1.143	P	1.145	P	1.148	P
3	0	0	2	7	3	-5	5	4	5	6	1.107	1.099	P	1.115	P	1.095	P	1.109	P	1.093	P
2	4	0	5	0	5	-5	5	1	4	2	1.486	1.474	P	1.482	P	1.485	P	1.491	P	1.470	P
0	7	2	6	0	-7	-6	5	5	0	0	1.072	1.070	P	1.074	P	1.074	P	1.074	P	1.072	P
0	0	0	4	0	0	0	0	2	0	5	1.091	1.107	P	1.081	P	1.087	P	1.115	P	1.082	P
3	1	0	4	0	-4	-3	4	3	0	0	1.191	1.188	P	1.184	P	1.181	P	1.189	P	1.191	P
0	0	0	2	0	-1	-3	4	2	0	1	1.235	1.211	P	1.252	P	1.260	P	1.242	P	1.250	P
1	2	0	4	3	-3	-6	4	4	5	0	1.108	1.111	P	1.115	P	1.105	P	1.103	P	1.106	P
-6	3	8	1	6	0	-2	1	3	7	7	0.977	0.975	P	0.976	P	0.978	P	0.978	P	0.977	P
0	0	0	0	5	0	0	0	5	6	9	1.037	1.042	P	1.036	P	1.036	P	1.038	P	1.039	P
-6	-3	0	0	0	0	0	0	0	0	0	1.320	1.312	P	1.328	P	1.323	P	1.321	P	1.319	P
0	0	0	7	0	0	-6	7	6	0	0	0.977	0.983	P	0.978	P	0.974	P	0.977	P	0.978	P
6	0	5	7	0	0	-7	4	4	7	1.237	1.242	P	1.241	P	1.243	P	1.239	P	1.232	P	
1	3	0	7	0	6	-5	4	6	2	5	1.109	1.114	P	1.107	P	1.106	P	1.103	P	1.123	P
-4	0	0	4	1	-3	-4	4	2	1	4	1.525	1.516	P	1.520	P	1.522	P	1.525	P	1.480	P
0	0	0	5	0	-6	-7	7	5	0	9	1.216	1.213	P	1.222	P	1.212	P	1.216	P	1.204	P
5	6	0	1	0	0	4	0	0	0	0	1.328	1.327	P	1.327	P	1.325	P	1.328	P	1.326	P
0	5	9	0	0	5	-5	5	0	5	0	1.005	1.004	P	1.003	P	1.004	P	1.005	P	1.005	P
4	5	0	5	2	7	-7	8	3	5	7	1.318	1.318	P	1.313	P	1.318	P	1.317	P	1.320	P
-1	-3	0	4	0	-6	-6	0	0	4	5	1.544	1.543	P	1.540	P	1.548	P	1.543	P	1.543	P
-3	4	3	1	3	3	3	3	3	0	0	0.851	0.849	P	0.852</							

# ANEXOS- Resultados Experimentais

Dados 2014											Modelo Estratégico 2014 - Conj. Teste 2015									
x <sub>0</sub>	x <sub>1</sub>	x <sub>2</sub>	x <sub>3</sub>	x <sub>4</sub>	x <sub>5</sub>	x <sub>6</sub>	x <sub>7</sub>	x <sub>8</sub>	x <sub>9</sub>	x <sub>10</sub>	y	RPropm	RProp	SAG	RPropAvg	AVG6	RPropmQ	RPropQ	SAGQ	
0	0	0	0	0	0	0	-5	1	1	8	8	1.074	1.076	P	1.072	P	1.073	P	1.077	P
1	5	0	5	0	7	-7	0	5	4	6	1.075	1.073	P	1.078	P	1.076	P	1.086	P	
7	7	0	7	0	-7	0	0	0	0	0	1.161	1.162	P	1.163	P	1.162	P	1.161	P	
-5	0	5	0	5	9	0	5	7	5	5	1.051	1.052	P	1.048	P	1.051	P	1.050	P	
4	9	0	8	0	6	0	0	9	0	9	1.206	1.208	P	1.208	P	1.206	P	1.209	P	
0	0	5	1	0	7	0	7	7	0	9	1.086	1.085	P	1.082	P	1.086	P	1.089	P	
5	9	0	0	0	9	-5	5	9	9	0	0.978	0.980	P	0.979	P	0.976	P	0.981	P	
5	6	0	5	0	5	-5	5	0	0	0	1.365	1.367	P	1.366	P	1.365	P	1.365	P	

Tabela A-42: Redes Neurais R - Resultados Dados 2014. Modelo Estratégico ME14T15 (R)

## Modelo Estratégico Global

Dados 2014											Modelo Estratégico Global (2013-2014-2015)										
x <sub>0</sub>	x <sub>1</sub>	x <sub>2</sub>	x <sub>3</sub>	x <sub>4</sub>	x <sub>5</sub>	x <sub>6</sub>	x <sub>7</sub>	x <sub>8</sub>	x <sub>9</sub>	x <sub>10</sub>	y	RPropm	RPropp	SAG	RPropAvg	AVG6	RPropmQ	RProppQ	SAGQ		
2	6	7	0	0	2	-3	0	0	0	0	0.929	0.927	P	0.928	P	0.929	P	0.924	P	0.930	P
-1	0	0	6	8	-7	-6	0	0	5	7	0.918	1.036	T	1.109	T	1.059	T	1.065	T	1.046	T
0	6	0	6	9	0	0	0	0	0	0	1.144	1.142	P	1.144	P	1.143	P	1.141	P	1.145	P
5	9	0	6	6	0	0	4	5	4	7	1.009	1.081	P	1.079	P	1.079	P	1.080	P	1.078	P
-5	0	2	0	0	0	-1	5	0	0	0	1.043	1.042	P	1.038	P	1.040	P	1.037	P	1.041	P
0	0	0	0	0	0	0	0	0	4	8	0.964	0.968	P	0.985	P	0.961	P	0.983	P	0.964	P
0	9	0	9	5	9	-9	0	6	0	8	1.250	1.193	P	1.193	P	1.193	P	1.188	P	1.191	P
7	8	3	0	0	8	-8	7	5	0	0	1.191	1.189	P	1.191	P	1.190	P	1.192	P	1.192	P
-6	-5	0	6	0	0	0	7	0	6	5	0.947	1.026	P	1.027	P	1.029	P	1.026	P	1.027	P
1	4	0	8	0	1	-3	0	4	0	0	1.084	0.732	T	1.196	T	1.088	T	0.957	T	1.103	T
2	3	0	2	9	4	-3	4	0	0	4	1.204	1.201	P	1.205	P	1.204	P	1.205	P	0.843	T
0	4	3	5	0	0	-1	0	0	0	2	1.352	1.345	P	1.350	P	1.344	P	1.353	P	1.355	P
0	2	0	0	6	3	-2	0	0	1	3	1.060	0.817	T	1.050	T	0.850	T	0.923	T	0.953	T
1	1	3	0	2	3	3	4	2	6	6	0.653	0.953	T	1.035	T	0.965	T	0.990	T	0.969	T
2	5	0	3	4	-4	-6	0	5	0	0	0.861	0.860	P	0.860	P	0.860	P	0.863	P	0.861	P
0	7	0	7	0	-8	-6	0	6	7	8	1.248	1.245	P	1.250	P	1.242	P	1.247	P	1.234	P
-3	-3	2	3	9	-3	-7	7	4	4	7	1.090	1.097	P	1.087	P	1.087	P	1.095	P	1.099	P
0	3	0	2	0	-4	-4	3	0	8	1.412	1.913	T	1.614	T	1.520	T	1.779	T	1.649	T	
6	7	0	5	4	5	-6	6	2	6	3	1.208	1.334	P	1.329	P	1.329	P	1.331	P	1.331	P
-6	6	6	4	5	0	-7	5	3	5	5	1.081	1.083	P	1.076	P	1.079	P	1.078	P	1.079	P
-8	7	0	0	0	6	-2	7	0	0	0	1.248	1.245	P	1.248	P	1.251	P	1.247	P	0.913	T
0	0	0	5	0	-2	-1	0	1	0	0	0.858	1.050	T	1.075	T	1.140	T	1.061	T	0.859	T
-2	-1	2	4	2	-5	-7	0	3	3	6	0.951	0.942	P	0.949	P	0.949	P	0.950	P	0.951	P
-2	6	0	3	0	6	-8	7	7	0	0	1.013	1.013	P	1.014	P	1.008	P	1.011	P	1.220	T
0	5	4	0	6	-9	-9	9	0	0	0	1.235	0.761	T	0.759	T	0.759	T	0.761	T	0.759	T
0	9	0	6	0	-4	-7	7	9	0	0	0.991	0.979	P	0.979	P	0.980	P	0.979	P	0.979	P
-1	-2	2	5	7	-5	-4	5	6	5	7	1.156	1.185	P	1.183	P	1.183	P	1.182	P	1.177	P
0	2	0	2	0	3	3	0	0	0	0	0.981	0.976	P	0.984	P	0.982	P	0.982	P	0.981	P
-4	1	1	2	0	4	-4	3	4	4	5	0.884	1.010	P	0.885	P	0.888	P	0.980	P	0.903	P
-4	0	0	6	0	-7	0	8	7	0	8	1.039	1.043	P	1.039	P	1.038	P	1.035	P	1.037	P
0	5	0	4	3	-5	0	5	0	0	0	1.041	0.984	P	0.983	P	0.983	P	0.982	P	0.983	P
4	7	1	7	4	7	0	8	8	4	4	1.308	1.306	P	1.296	P	1.309	P	1.303	P	1.301	P
-6	-1	9	2	0	-6	-6	0	0	8	9	1.126	1.088	P	1.086	P	1.087	P	1.086	P	1.085	P
0	5	0	5	0	-6	0	5	5	0	5	1.206	1.216	P	1.207	P	1.203	P	1.212	P	1.209	P
-2	0	0	0	7	9	-7	2	6	2	8	1.051	1.050	P	1.049	P	1.053	P	1.050	P	1.089	T
-6	0	0	0	0	6	-5	0	6	0	6	0.617	0.616	P	0.618	P	0.618	P	0.617	P	0.619	P
-2	-4	6	0	0	0	-4	2	0	0	6	0.607	0.612	P	0.607	P	0.605	P	0.609	P	0.606	P
0	8	0	8	6	-6	-5	7	0	0	8	1.039	1.137	T	1.120	T	1.233	T	1.129	T	1.039	P
3	7	0	0	0	-8	0	8	6	0	0	1.050	1.045	P	1.050	P	1.046	P	1.043	P	1.044	P
0	7	0	2	2	-5	-3	0	3	7	0	0.861	0.861	P	0.861	P	0.862	P	0.862	P	0.860	P
-4	9	0	8	0	-9	-1	0	0	0	2	1.244	1.206	P	1.207	P	1.207	P	1.208	P	1.207	P
6	6	0	0	0	6	0	6	8	0	0	1.170	1.025	T	1.228	T	0.876	T	1.113	T	0.880	T
0	0	4	0	9	0	1	1	0	0	0	0.907	0.945	T	0.926	T	0.811	T	0.919	T	1.195	T
0	0	0	5	5	-5	0	0	0	5	9	0.952	0.987	P	0.987	P	0.986	P	0.987	P	0.986	P
-3	8	0	2	0	0	-6	0	0	0	7	1.209	1.240	T	1.188	T	1.496	T	1.213	T	1.443	T
1	4	2	0	0	8	2	8	8	0	8	1.076	0.947	P	0.946	P	0.947	P	0.949	P	0.947	P
0	7	0	0	6	-6	-7	0	4	0	6	1.259	1.256	P	1.258	P	1.258	P	1.265	P	1.260	P
-8	0	6	1	2	1	4	2	3	2	4	1.193	1.193	P	1.194	P	1.192	P	1.193	P	1.196	P
-5	-5	5	5	5	5	5	5	5	5	5	1.013	1.013	P	1.013	P	1.011	P	1.013	P	2.094	T
2	4	0	0	0	6	-4	1	0	0	2	1.292	1.290	P	1.289	P	1.293	P	1.292	P	1.294	P
0	8	0	5	0	0	-9	0	9	3	0	0.943	1.354	T	0.942	T	1.403	T	1.143	T	0.944	P
1	3	0	0	2	2	3	3	3	0	4	0.998	1.004	P	0.997	P	0.997	P	1.002	P	1.005	P
4	-5	5	6	6	5	0	5	6	6	6	1.749	1.753	P	1.748	P	1.749	P	1.749	P	1.749	P
0	-5	6	0	0	4	-6	0	7	6	6	0.999	1.589	T	1.306	T	1.334	T	1.451	T	1.127	T
-6	3	0	2	0	2	-4	0	0	1	2	0.966	1.206	T	1.123	T	0.978	T	1.180	T	1.136	T
0	7	1	3	6	-5	7	3	4	3	1	0.954	0.957	P	0.955	P	0.955	P	0.956	P	0.955	P
1	-1	0	1	0	0	-2	1	0	0	2	1.043	1.026	P	1.042	P	1.050	P	1.029	P	1.041	P
-7	9	8	9	0	0	0	0	0	0	6	0.731	0.733	P	0.731	P	0.732	P	0.731	P	0.734	P
-2	-2	2	6	9	-7	-8	3	5	7	4	1.168	1.167	P	1.166	P	1.169	P	1.166	P	1.155	P
-5	-3	5	0	6	-5	-5	6	7	7	2	0.906	0.906	P	0.906	P	0.907	P	0.909	P	0.907	P
4	7	0	0	0	0	4	0	0	0	0	1.238	1.237	P	1.238	P	1.237	P	1.239	P	1.238	P
7	6	0	5	0	-5	-5	5	5	5	5	1.963	1.966	P	1.977	P	1.961	P	1.964	P	1.939	P
-7	-5	0	4	0	-4	-3	0	4	4	0	1.069	0.945	T	0.967	T	1.002	T	0.957	T	1.017	T
1	5	0	1	0	7	-8	2	8	0	4	1.218	1.217	P	1.218	P	1.219	P	1.211	P	1.216	P
5	4	0	5	0	-6	-5	0	2	0	4	1.396	1.397	P	1.395	P	1.397	P	1.393	P	1.395	P
0	0	3	0	0	0	-3	0	3	2	0	0.863	0.872	P	0.860	P	0.863	P	0.874	P	0.863	P
6	5	1	5	0	0	0	0	5	0	6	1.502	1.503	P	1.502	P	1.502	P	1.500	P	1.503	P
0	8	0	0	0	7	-7	0	8	0	0	0.992	0.985	P	0.892	P	0.894	P	0.892	P	0.791	T
3	6	0	8	0	-4	0	7	8	7	4	1.056	1.057	P	1.056	P	1.053	P	1.057	P	1.041	P
0	0	0	0	0	-5	0	0	0	4	4	0.524	0.771	T	0.963	T	1.019	T	0.860	T	0.265	T
5	8	0	4	0	-8	-1	8	6	7	4	0.984	1.129	T	1.059	T	1.434	T	1.109	T	0.852	T
-2	5	0	0	8	6	-3	7	5	0	0	1.151	1.150	P	1.150	P	1.153	P	1.151	P	1.149	P
-4	4	0	4	4	3	-4	0	0	4	4	0.966	0.946	P	0.941	P	0.950	P	0.949	P	0.957	P
0	0	0	6	0	-6	-7	6	6	6	0	1.077	1.078	P	1.077	P	1.077	P	1.080	P	1.107	P
-5	3	3	5	3	-5	0	0	5	5	6	1.287	1.284	P	1.285	P	1.288	P	1.291	P	1.278	P
5	5	0	5	0	-5	-5	5	5	5	1	0.99	1.149	T	1.139	T	1.139	T	1.135	T	1.115	T
-6	5	0	5	0	-3	-4	3	3	2	5	1.140	1.078	T	1.371	T	1.165	T	1.201	T	1.202	T
7	6	0	4	0	6	3	5	8	5	0	1.173	1.279	T	1.218	T	1.381	T	1.250	T	1.365	T
3	4	0	4	3	5	-4	3	5													

# ANEXOS- Resultados Experimentais

Dados 2014													Modelo Estratégico Global (2013-2014-2015)													
0	1	2	3	4	5	6	7	8	9	10	11	12	RPropm	RPropp	SAG	RPropAvg	AVG6	RPropmQ	RProppQ	SAGQ						
0	4	0	4	0	7	-2	0	3	0	0	0.987	1.208	T	1.592	T	1.209	T	1.416	T	1.514	T	0.988	P	0.988	P	
5	6	0	6	0	6	-5	2	4	0	4	0.781	1.218	T	1.217	T	1.215	T	1.213	T	1.212	T	0.781	P	0.783	P	
-3	0	0	3	0	-6	-5	5	2	2	6	1.380	1.080	T	1.486	T	1.290	T	1.285	T	1.518	T	1.384	P	1.378	P	
-7	0	2	4	0	0	0	9	2	7	9	1.029	1.027	P	1.030	P	1.030	P	1.029	P	1.030	P	1.030	P	1.028	P	
-5	4	0	2	0	0	0	0	3	2	0	0.972	1.130	T	1.090	T	0.836	T	1.118	T	0.991	T	0.971	P	1.028	P	
-3	6	0	6	5	-4	8	0	0	6	0	1.131	0.586	T	0.860	T	0.916	T	0.748	T	0.894	T	1.130	P	1.130	P	
1	5	0	1	0	-2	0	0	0	0	0	1.274	1.277	P	1.270	P	1.275	P	1.261	P	1.274	P	0.825	T	1.393	T	
0	9	3	9	0	-5	9	0	5	8	6	1.758	1.758	P	1.758	P	1.758	P	1.758	P	1.755	P	1.111	T	1.017	T	
0	0	0	0	0	1	0	0	0	0	8	0.909	1.001	T	1.384	T	0.979	T	1.181	T	1.779	T	0.909	P	0.908	P	
6	5	0	9	0	6	-4	6	4	0	4	0.711	0.714	P	0.713	P	0.712	P	0.714	P	0.715	P	1.168	T	0.744	T	
0	0	0	9	0	-9	-9	5	9	0	5	1.346	0.760	T	1.119	T	0.990	T	0.960	T	1.142	T	1.194	T	1.397	T	
0	8	0	3	9	-5	-5	3	5	0	5	1.106	1.105	P	1.106	P	1.107	P	1.103	P	1.111	P	1.107	P	1.103	P	
0	9	0	0	0	9	-3	9	5	0	2	1.491	1.141	T	1.501	T	1.330	T	1.320	T	1.242	T	1.491	P	1.491	P	
0	0	8	9	0	-9	-9	5	5	0	0	1.763	1.765	P	1.763	P	1.762	P	1.766	P	1.764	P	0.991	T	0.924	T	
-4	4	0	0	0	-3	0	4	4	4	4	1.152	0.881	T	1.085	T	1.129	T	0.993	T	1.042	T	1.010	T	1.122	T	
-1	-1	0	0	0	-7	0	1	7	0	4	1.081	1.029	P	1.028	P	1.028	P	1.029	P	1.030	P	1.048	P	1.046	P	
-6	0	0	5	0	-5	0	0	6	0	7	1.043	0.965	T	0.954	T	0.774	T	0.920	T	0.791	T	0.974	P	0.973	P	
-2	-1	7	0	1	0	-4	4	3	1	7	0.845	0.900	P	0.850	P	0.891	P	0.884	P	0.854	P	0.843	P	0.845	P	
-5	-1	5	4	2	-6	-4	3	2	4	6	0.562	0.561	P	0.564	P	0.563	P	0.569	P	0.560	P	0.562	P	0.563	P	
1	4	0	3	0	0	0	0	3	6	0	1.133	1.144	P	1.131	P	1.124	P	1.124	P	1.132	P	1.125	P	1.133	P	
0	4	0	2	0	-5	-4	0	0	2	3	0.966	1.142	T	1.159	T	1.088	T	1.151	T	1.081	T	0.964	P	0.965	P	
-5	7	5	7	5	6	-5	3	0	4	5	0.988	0.984	P	0.987	P	0.987	P	0.986	P	0.986	P	1.246	T	1.126	T	
-6	6	0	0	0	8	0	-2	4	0	0	3	0.918	0.918	P	0.917	P	0.920	P	0.917	P	0.916	P	0.919	P	0.918	P
5	4	0	0	0	0	-1	6	6	0	5	0.865	0.869	P	0.864	P	0.865	P	0.861	P	0.864	P	0.989	T	0.814	T	
6	0	5	0	0	-5	-6	6	0	0	5	0.893	0.894	P	0.892	P	0.892	P	0.894	P	0.892	P	1.350	T	1.357	T	
-7	-2	6	0	0	-4	0	0	6	7	9	0.757	1.237	T	0.937	T	0.617	T	1.089	T	0.906	T	0.758	P	0.759	P	
-3	0	8	7	7	0	0	0	0	0	3	1.145	1.144	P	1.146	P	1.146	P	1.146	P	1.144	P	1.039	T	0.930	T	
-7	0	0	2	7	3	-5	5	4	5	6	1.107	1.092	P	1.105	P	1.105	P	1.108	P	1.108	P	1.108	P	1.108	P	
2	4	0	5	0	5	-5	5	1	4	2	1.486	0.967	T	1.144	T	1.068	T	1.055	T	1.069	T	1.486	P	1.487	P	
0	7	2	6	0	-7	-6	5	5	0	0	1.072	1.074	P	1.074	P	1.074	P	1.076	P	1.072	P	0.836	T	1.128	T	
3	0	0	4	0	0	0	0	2	0	5	1.091	1.199	T	1.292	T	1.212	T	1.241	T	1.218	T	1.090	P	1.092	P	
0	1	0	4	0	-4	-3	4	3	0	0	1.191	1.194	P	1.194	P	1.191	P	1.187	P	1.186	P	1.194	P	1.190	P	
0	0	0	2	0	-3	-3	4	2	0	1	1.235	1.216	P	1.227	P	1.241	P	1.220	P	1.230	P	1.237	P	1.239	P	
2	1	0	4	3	-3	-6	4	4	5	0	1.108	1.104	P	1.113	P	1.111	P	1.106	P	1.098	P	1.271	T	0.718	T	
-6	3	8	1	6	0	-2	1	3	7	7	0.977	0.981	P	0.977	P	0.979	P	0.977	P	0.978	P	0.931	T	1.070	T	
0	0	0	0	5	0	0	0	5	6	9	1.037	1.026	P	1.041	P	1.035	P	1.030	P	1.037	P	1.037	P	1.038	P	
-6	-3	0	0	0	0	0	0	0	0	0	1.320	1.438	T	1.181	T	1.283	T	1.314	T	1.205	T	1.320	P	1.320	P	
0	0	0	7	0	0	-6	7	6	0	0	0.977	0.857	T	0.896	T	0.888	T	0.913	T	0.944	T	0.939	T	0.876	T	
-6	0	5	7	0	0	-7	3	4	4	7	1.237	1.237	P	1.224	P	1.217	P	1.226	P	1.207	P	1.160	T	1.178	T	
1	3	0	7	0	6	-5	4	6	2	5	1.109	0.922	T	0.794	T	0.843	T	0.860	T	0.839	T	0.940	T	0.778	T	
-4	0	0	4	1	-3	-4	4	2	1	4	1.525	1.525	P	1.521	P	1.501	P	1.527	P	1.525	P	1.525	P	1.526	P	
0	0	0	5	0	-6	-7	7	5	0	9	1.216	1.218	P	1.218	P	1.213	P	1.216	P	1.216	P	1.211	P	1.222	P	
5	6	0	1	0	4	0	4	0	0	0	1.328	1.330	P	1.328	P	1.327	P	1.329	P	1.328	P	1.327	P	1.327	P	
0	5	9	0	0	5	-5	5	0	5	0	1.005	1.007	P	1.006	P	1.006	P	1.007	P	1.005	P	1.006	P	1.004	P	
4	5	0	5	2	7	-7	8	3	5	7	1.318	1.318	P	1.315	P	1.315	P	1.318	P	1.315	P	1.318	P	1.317	P	
-1	-3	0	4	0	-6	-6	0	0	4	5	1.544	0.873	T	0.868	T	0.909	T	0.877	T	0.831	T	1.546	P	1.545	P	
-3	4	3	1	3	3	3	3	3	3	0	0.851	0.831	P	0.850	P	0.847	P	0.841	P	0.829	P	0.849	P	0.843	P	
-2	0	0	0	3	0	-6	6	0	0	0	1.206	1.214	P	1.205	P	1.204	P	1.209	P	1.206	P	1.205	P	1.205	P	
-2	0	0	0	0	0	-1	0	3	0	4	0.929	0.929	P	0.930	P	0.925	P	0.924	P	0.934	P	0.930	P	0.932	P	
8	8	0	5	6	4	-5	7	4	0	0	1.113	0.908	T	1.396	T	1.236	T	1.193	T	1.191	T	1.114	P	1.109	P	
8	0	5	5	0	0	-4	6	7	7	8	1.015	1.020	P	1.019	P	1.015	P	1.010	P	1.015	P	1.015	P	1.015	P	
-1	6	0	2	9	-9	-4	5	6	4	2	0.970	0.969	P	0.971	P	0.969	P	0.980	P	0.980	P	1.094	P	1.047	P	
0	0	0	0	0	-5	-2	3	1	0	0	1.072	1.070	P	1.071	P	1.071	P	1.075	P	1.073	P	1.199	T	1.403	T	
0	0	4	7	0	-5	-8	3	4	3	4	1.346	0.941	T	0.944	T	0.940	T	0.956	T	0.952	T	1.143	P	1.145	P	
5	6	0	7	0	0	0	5	2	0	7	1.114	1.112	P	1.114	P	1.112	P	1.121	P	1.113	P	0.980	T	0.759	T	
5	5	0	5	0	4	-2	8	5	0	5	1.164	1.168	P	1.161	P	1.163	P	1.158	P	1.166	P	1.095	T	0.962	T	
0	0	0	0	0	0	0	0	0	4	9	1.152	1.153	P	1.133	P	1.149	P	1.142	P	1.152	P	1.153	P	1.152	P	
0	6	0	5	4	0	-5	0	7	0	5	1.065	1.095	P	1.069	P	1.054	P	1.082	P	1.074	P	1.063	P	1.067	P	
2	3	0	0	4	-4	0	0	3	0	2	0.986	1.142	T	0.921	T	1.304	T	1.049	T	0.552	T	0.980	P	0.981	P	
8	8	0	7	0	8	7	7	5	0	5	1.033	1.051	P	1.052	P	1.051	P	1.052	P	1.051	P	1.051	P	1.053	P	
0	0	0	1	0	-5	-6	0	3	0	0	1.358	1.362	P	1.356	P	1.358	P	1.361	P	1.361	P	1.359	P	1.361	P	
6	7	0	9	0	8	-9	0	7	0	7	1.051	1.051	P	1.051	P	1.051	P	1.051	P	1.053	P	0.830	T	1.118	T	
0	4	0	4	0	-4	-7	0	5	7	6	0.896	0.892	P	0.896	P	0.928	P	0.895	P	0.916	P	0.894	P	0.899	P	
5	5	0	4	3	-4	-4	5	2	0	5	1.749	1.243	P	1.241	P	1.242	P	1.242	P	1.241	P	0.732				

## ANEXOS- Resultados Experimentais

**R Dados 2015**

Modelo Estratégico 2015

Dados 2015											Modelo Estratégico 2015										
x <sub>0</sub>	x <sub>1</sub>	x <sub>2</sub>	x <sub>3</sub>	x <sub>4</sub>	x <sub>5</sub>	x <sub>6</sub>	x <sub>7</sub>	x <sub>8</sub>	x <sub>9</sub>	x <sub>10</sub>	y	RPropm	RPropp	SAG	RPropAvg	AVG6	RPropmQ	RProppQ	SAGQ	P	
-1	0	0	4	0	-6	-7	0	0	4	5	0.849	0.840	P	0.862	P	0.852	P	0.846	P	0.848	P
-1	0	0	8	8	-7	-6	0	0	6	7	0.990	0.987	P	0.986	P	0.987	P	0.989	P	0.988	P
-5	7	0	8	7	8	-8	8	0	0	8	1.035	1.035	P	1.029	P	1.030	P	1.038	P	1.038	P
0	6	0	9	0	0	0	0	0	0	0	1.029	1.039	P	1.026	P	1.027	P	1.030	P	1.030	P
0	5	3	7	0	-3	-5	0	6	4	6	1.129	1.133	P	1.127	P	1.126	P	1.124	P	1.127	P
-6	0	0	5	0	5	0	0	6	0	7	0.902	0.899	P	0.904	P	0.902	P	0.905	P	0.932	P
-7	0	0	0	0	0	-1	5	0	0	0	0.961	0.962	P	0.962	P	0.959	P	0.961	P	0.958	P
-3	5	3	1	3	3	3	3	3	4	0	0.914	0.912	P	0.910	P	0.913	P	0.915	P	0.913	P
0	9	0	9	5	9	-9	0	6	0	8	1.135	1.132	P	1.136	P	1.133	P	1.133	P	1.134	P
7	-5	5	0	7	0	-5	0	7	0	0	0.730	0.730	P	0.728	P	0.729	P	0.732	P	0.729	P
0	0	7	7	6	0	-8	7	8	6	7	1.171	1.180	P	1.177	P	1.169	P	1.171	P	1.157	P
-6	-5	0	6	0	0	0	7	0	6	5	1.119	1.114	P	1.117	P	1.113	P	1.114	P	1.119	P
-3	0	0	3	4	0	-4	3	0	0	0	1.024	1.023	P	1.026	P	1.029	P	1.024	P	1.029	P
0	4	3	5	0	0	-1	0	0	0	4	1.716	1.707	P	1.715	P	1.718	P	1.721	P	1.716	P
2	2	0	2	6	3	-4	0	0	4	3	1.015	1.016	P	1.011	P	1.019	P	1.021	P	1.018	P
2	5	0	3	3	-6	-7	0	4	0	0	0.953	0.936	P	0.954	P	0.959	P	0.956	P	0.961	P
-3	-3	2	4	9	-4	-7	7	4	4	7	1.074	1.066	P	1.071	P	1.072	P	1.068	P	1.070	P
6	7	0	5	4	5	-6	6	2	6	3	1.452	1.451	P	1.434	P	1.453	P	1.452	P	1.435	P
-8	0	0	8	5	0	-4	6	7	7	8	0.956	0.970	P	0.961	P	0.956	P	0.960	P	0.985	P
-1	-2	5	2	7	0	-7	8	3	0	9	0.986	0.996	P	0.985	P	0.986	P	0.982	P	0.984	P
-2	6	0	8	0	7	-7	7	8	0	0	1.155	1.168	P	1.159	P	1.156	P	1.156	P	1.147	P
0	5	4	0	6	-9	-9	9	0	0	0	1.055	1.055	P	1.057	P	1.055	P	1.056	P	1.054	P
0	9	0	6	0	-4	-7	7	9	0	0	0.756	0.761	P	0.755	P	0.758	P	0.755	P	0.779	P
3	5	0	5	6	-7	-5	0	3	7	7	1.035	1.037	P	1.033	P	1.032	P	1.040	P	1.047	P
0	-5	5	6	0	5	0	5	0	0	7	0.789	0.789	P	0.787	P	0.789	P	0.787	P	0.799	P
0	2	0	2	0	3	3	0	2	0	0	1.013	1.022	P	1.014	P	1.015	P	1.010	P	1.021	P
-5	2	2	4	0	6	-5	5	4	7	8	1.200	1.162	P	1.194	P	1.204	P	1.208	P	1.151	P
0	5	0	4	4	-7	0	5	0	0	0	1.085	1.088	P	1.081	P	1.083	P	1.084	P	1.084	P
5	8	1	8	5	8	0	9	9	4	4	1.285	1.293	P	1.285	P	1.277	P	1.288	P	1.272	P
0	0	4	7	0	-5	-8	3	4	3	4	0.944	0.946	P	0.938	P	0.941	P	0.958	P	0.967	P
-2	0	0	0	0	9	-7	2	5	2	8	1.205	1.202	P	1.202	P	1.203	P	1.202	P	1.203	P
8	8	0	8	0	0	5	2	0	0	0	1.244	1.248	P	1.242	P	1.243	P	1.243	P	1.246	P
0	8	0	8	0	8	-7	3	6	5	7	0.987	0.996	P	0.983	P	0.984	P	0.953	P	0.967	P
0	0	0	0	0	-7	0	0	8	0	0	1.166	1.152	P	1.165	P	1.169	P	1.164	P	1.162	P
-4	9	0	8	0	-9	-1	0	0	0	2	1.171	1.169	P	1.169	P	1.170	P	1.173	P	1.169	P
5	5	0	0	0	9	-9	6	9	0	9	0.601	0.594	P	0.605	P	0.600	P	0.595	P	0.600	P
-4	5	0	0	0	5	0	8	5	0	5	1.128	1.132	P	1.126	P	1.119	P	1.129	P	1.131	P
-4	-7	9	9	0	-6	-6	2	7	2	3	1.104	1.098	P	1.104	P	1.104	P	1.103	P	1.103	P
0	6	0	6	0	6	0	6	8	0	0	1.033	1.037	P	1.031	P	1.044	P	1.033	P	1.030	P
1	1	0	7	0	0	-2	2	0	0	2	0.899	0.927	P	0.891	P	0.890	P	0.897	P	0.896	P
-9	-8	1	8	5	0	0	7	0	8	7	1.228	1.227	P	1.229	P	1.228	P	1.224	P	1.205	P
-5	0	0	3	4	-4	-8	0	0	4	9	1.004	1.005	P	1.003	P	1.000	P	0.999	P	1.002	P
0	0	0	0	0	0	0	0	9	9	9	1.111	1.119	P	1.105	P	1.107	P	1.112	P	1.112	P
0	7	0	8	6	-6	-7	0	4	5	6	1.025	1.040	P	1.020	P	1.025	P	1.056	P	1.044	P
-7	0	7	2	4	2	6	5	6	3	7	1.712	1.710	P	1.712	P	1.714	P	1.711	P	1.712	P
5	0	5	0	0	-5	-5	6	6	5	5	1.044	1.043	P	1.043	P	1.048	P	1.042	P	1.033	P
5	5	0	8	0	6	0	5	4	0	5	1.142	1.127	P	1.141	P	1.142	P	1.142	P	1.134	P
-5	-5	5	5	5	5	5	5	0	5	0.994	0.986	P	0.998	P	0.994	P	0.995	P	1.015	P	
4	9	0	8	0	0	0	0	9	0	0	1.422	1.425	P	1.423	P	1.421	P	1.423	P	1.422	P
2	-2	0	0	1	2	2	3	2	0	4	0.938	0.920	P	0.938	P	0.945	P	0.936	P	0.947	P
0	3	0	0	4	-4	0	0	3	0	2	1.000	1.011	P	1.002	P	1.001	P	0.999	P	1.004	P
0	3	0	1	2	5	7	-7	0	7	1	0.974	0.987	P	0.967	P	0.971	P	0.974	P	0.973	P
-6	3	0	2	0	2	-4	0	0	1	2	1.156	1.162	P	1.154	P	1.153	P	1.160	P	1.155	P
5	-5	0	6	0	6	8	0	9	0	9	1.026	1.030	P	1.025	P	1.024	P	1.025	P	1.017	P
-6	0	4	4	4	6	-6	7	3	3	6	1.018	1.032	P	1.015	P	1.018	P	1.019	P	1.033	P
7	7	1	0	3	8	-8	8	5	5	7	1.151	1.163	P	1.149	P	1.155	P	1.156	P	1.164	P
-5	7	5	7	6	-6	-6	6	7	6	1	1.015	1.015	P	1.010	P	1.016	P	1.014	P	1.022	P
-6	-2	0	8	0	-8	-9	8	7	8	0	0.848	0.841	P	0.847	P	0.851	P	0.842	P	0.856	P
-6	-5	0	5	0	-4	-3	0	4	5	0	0.947	0.948	P	0.948	P	0.950	P	0.947	P	0.951	P
2	6	0	9	0	7	-6	5	1	9	7	0.914	0.920	P	0.910	P	0.913	P	0.914	P	0.943	P
0	7	2	6	0	-7	-6	5	6	6	0	1.125	1.127	P	1.117	P	1.124	P	1.132	P	1.087	P
1	4	0	3	0	-5	-8	0	7	8	7	0.978	0.986	P	0.981	P	0.980	P	0.977	P	0.999	P
6	5	0	6	0	-6	-6	0	7	5	7	1.165	1.150	P	1.166	P	1.167	P	1.161	P	1.154	P
0	9	0	4	0	-1	-3	0	0	0	0	0.970	0.949	P	0.972	P	0.969	P	0.962	P	0.976	P
0	0	0	6	0	0	0	0	2	0	6	1.329	1.389	P	1.334	P	1.342	P	1.323	P	1.334	P
3	7	0	8	0	-8	0	7	3	9	5	1.043	1.042	P	1.044	P	1.039	P	1.043	P	1.047	P
-1	0	0	4	9	-9	-8	9	8	9	5	1.053	1.062	P	1.058	P	1.054	P	1.053	P	1.088	P
0	8	0	2	0	-8	-3	4	6	8	4	0.996	0.9									

# ANEXOS- Resultados Experimentais

Dados 2015											Modelo Estratégico 2015										
x <sub>0</sub>	x <sub>1</sub>	x <sub>2</sub>	x <sub>3</sub>	x <sub>4</sub>	x <sub>5</sub>	x <sub>6</sub>	x <sub>7</sub>	x <sub>8</sub>	x <sub>9</sub>	x <sub>10</sub>	y	RPropm	RPropp	SAG	RPropAvg	AVG6	RPropmQ	RProppQ	SAGQ		
0	0	0	0	0	0	-5	-1	8	8	8	1.100	1.113	P	1.095	P	1.102	P	1.105	P	1.091	P
-5	5	0	7	0	-9	-7	7	3	6	8	1.918	1.917	P	1.915	P	1.915	P	1.917	P	1.925	P
0	8	0	0	0	7	-9	8	0	8	9	1.213	1.230	P	1.215	P	1.217	P	1.216	P	1.230	P
4	8	0	2	0	-6	-7	0	3	0	5	1.752	1.759	P	1.752	P	1.749	P	1.751	P	1.753	P
7	7	0	7	0	7	0	7	0	0	0	1.009	1.006	P	1.008	P	1.007	P	1.015	P	1.009	P
0	5	0	0	0	5	-5	5	0	5	0	1.221	1.220	P	1.217	P	1.214	P	1.218	P	1.222	P
-5	0	0	0	0	0	-9	8	0	8	0	0.658	0.661	P	0.655	P	0.661	P	0.660	P	0.658	P
5	9	0	8	0	6	0	0	0	9	0	1.038	1.037	P	1.030	P	1.038	P	1.036	P	1.033	P
5	9	0	0	0	9	-5	5	9	3	0	1.088	1.102	P	1.084	P	1.093	P	1.090	P	1.091	P
6	9	0	6	5	-9	9	4	0	5	6	1.182	1.173	P	1.181	P	1.182	P	1.181	P	1.184	P
3	9	0	2	0	9	-3	9	5	0	5	1.138	1.134	P	1.140	P	1.137	P	1.134	P	1.140	P
5	9	0	5	0	-5	-9	0	0	5	5	1.897	1.894	P	1.891	P	1.900	P	1.897	P	1.898	P
0	-3	0	0	0	0	-3	0	0	0	4	0.974	0.967	P	0.974	P	0.973	P	0.970	P	0.974	P
0	0	0	0	0	9	-9	9	9	0	0	1.243	1.241	P	1.242	P	1.243	P	1.244	P	1.243	P
7	6	0	5	0	8	-5	5	0	0	0	1.269	1.273	P	1.266	P	1.271	P	1.268	P	1.270	P
-1	-1	0	0	0	-7	0	1	7	0	4	0.991	1.041	P	0.990	P	0.991	P	0.995	P	0.992	P
5	8	0	0	0	-5	-5	0	0	0	0	0.957	1.220	T	1.354	T	0.766	T	1.148	T	1.290	T
3	7	0	5	0	3	0	0	0	0	0	1.822	1.172	T	1.119	T	1.041	T	1.118	T	1.234	T
-2	-1	7	0	1	0	-5	5	5	5	7	1.366	1.070	T	1.173	T	0.890	T	1.039	T	1.181	T
-5	0	1	5	0	-9	-5	7	0	5	9	0.916	1.795	T	1.258	T	1.867	T	0.978	T	1.641	T
7	7	0	6	0	0	-6	0	0	0	6	1.485	1.949	T	1.623	T	2.340	T	1.383	T	1.755	T
-6	6	3	4	0	3	0	4	4	0	0	1.052	0.938	T	1.056	T	1.018	T	1.055	T	1.070	T
-7	8	5	5	7	7	-7	0	0	6	6	1.002	1.216	T	1.335	T	1.440	T	1.252	T	1.278	T
-8	6	3	8	5	0	-8	5	3	7	5	0.958	1.188	T	1.207	T	1.242	T	1.260	T	1.242	T
-2	7	0	4	0	-6	-4	0	0	2	4	1.032	1.444	T	1.207	T	1.156	T	1.158	T	1.311	T
0	0	0	5	4	-3	-1	0	2	0	0	1.200	0.991	T	1.127	T	1.095	T	1.179	T	1.122	T
-1	6	0	2	9	-9	-4	6	6	4	2	1.634	1.151	T	0.831	T	1.065	T	1.069	T	1.097	T
0	0	0	5	0	-7	0	8	7	0	8	0.994	1.049	T	1.226	T	1.184	T	1.161	T	1.333	T
0	0	0	0	0	-7	3	4	1	0	0	1.226	1.123	T	1.066	T	0.884	T	1.012	T	1.121	T
-6	-1	9	2	0	8	-6	0	0	8	9	0.765	1.004	T	1.261	T	1.074	T	1.104	T	1.106	T
0	9	0	8	0	6	-8	7	5	7	6	1.368	1.295	T	1.247	T	1.087	T	1.108	T	1.114	T
0	15	6	0	8	6	-5	8	6	6	5	0.655	0.976	T	1.151	T	1.110	T	0.951	T	1.125	T
6	7	0	0	0	-8	-0	8	6	0	0	1.118	0.886	T	0.816	T	0.861	T	1.033	T	0.945	T
0	0	0	5	5	-5	0	0	0	5	9	1.022	1.026	T	1.230	T	1.213	T	1.222	T	1.038	T
3	5	0	1	3	6	-4	1	0	0	2	0.796	1.168	T	1.224	T	0.995	T	1.138	T	1.411	T
-3	0	0	0	0	2	0	2	6	0	0	1.076	1.031	T	1.051	T	1.254	T	0.986	T	1.085	T
0	-6	0	0	0	0	-5	0	0	0	4	1.237	0.951	T	0.916	T	0.680	T	0.837	T	0.825	T
1	-2	0	5	3	-3	-3	1	0	5	3	1.010	0.871	T	0.880	T	0.964	T	0.971	T	0.887	T
4	6	4	6	5	8	-6	0	2	0	2	1.115	1.373	T	1.173	T	1.594	T	1.063	T	1.401	T
8	8	0	7	0	8	7	7	5	0	5	1.070	1.322	T	1.029	T	1.558	T	1.093	T	1.183	T
7	7	0	6	0	-6	-6	6	6	6	6	1.153	1.290	T	1.116	T	1.273	T	1.279	T	1.271	T
0	0	5	3	0	-6	3	0	6	3	4	1.117	1.071	T	1.430	T	1.185	T	1.148	T	1.142	T
1	6	0	1	0	7	-8	2	8	0	6	1.237	0.757	T	0.952	T	0.732	T	0.702	T	0.759	T
0	8	0	0	0	7	-7	0	8	0	0	0.792	0.900	T	1.127	T	1.060	T	0.816	T	0.850	T
5	7	0	5	4	-4	0	8	8	5	7	1.118	1.054	T	1.114	T	1.324	T	1.173	T	1.188	T
-5	6	2	7	1	-7	0	0	6	7	7	1.018	1.161	T	0.946	T	1.198	T	1.074	T	1.332	T
2	2	0	4	0	5	3	5	8	6	0	1.033	0.910	T	1.089	T	1.125	T	1.093	T	1.106	T
5	8	0	5	0	0	0	0	0	5	1.520	1.767	T	1.566	T	2.007	T	1.230	T	1.850	T	
-3	-5	2	3	3	-5	-5	5	1	3	0.915	0.945	T	1.050	T	1.088	T	0.933	T	1.047	T	
-2	0	0	2	0	6	-3	0	0	0	0	1.141	1.109	T	1.067	T	1.039	T	0.818	T	0.901	T
0	7	6	0	5	-5	-5	3	0	3	6	1.040	1.187	T	1.330	T	1.350	T	1.449	T	1.159	T
5	5	0	0	4	7	-5	4	2	0	4	1.600	1.310	T	1.282	T	1.084	T	1.104	T	1.265	T
6	7	0	3	0	7	0	0	7	2	8	0.957	1.239	T	0.966	T	1.362	T	0.980	T	1.288	T
4	5	7	7	5	-5	-2	2	6	3	1.017	1.126	T	1.321	T	1.072	T	1.039	T	1.263	T	
-3	3	0	1	0	-5	-4	0	4	3	4	1.071	1.115	T	1.024	T	1.131	T	1.028	T	1.292	T
-5	9	0	7	0	0	-9	0	9	0	9	1.259	1.078	T	1.087	T	0.362	T	1.046	T	1.046	T
6	7	0	3	0	-7	-7	6	2	0	0	1.069	1.139	T	1.380	T	1.182	T	1.193	T	1.230	T
-4	0	0	7	0	-7	-8	7	6	4	7	1.149	1.510	T	1.325	T	1.157	T	1.165	T	1.428	T
5	5	0	0	0	-4	-3	0	0	0	0	1.121	1.058	T	1.134	T	0.867	T	1.125	T	1.205	T
6	7	0	8	0	7	-9	0	7	7	7	1.373	1.072	T	0.644	T	1.067	T	0.949	T	0.986	T
9	0	5	6	8	-6	-8	1	7	0	9	1.094	1.104	T	1.353	T	1.388	T	1.146	T	1.141	T
-7	6	0	1	3	4	-6	7	5	0	5	1.295	1.211	T	1.188	T	1.204	T	1.137	T	1.190	T
2	3	0	3	0	5	-4	0	4	0	0	1.561	1.008	T	1.179	T	1.046	T	0.994	T	0.811	T
0	7	0	4	0	6	0	3	0	0	0	1.792	1.040	T	1.081	T	0.890	T	1.064	T	0.943	T
4	4	0	1	0	7	0	0	3	0	0	0.960	1.033	T	1.284	T	0.524	T	1.005	T	0.836	T

Tabela A-44: Redes Neurais R - Resultados Dados 2015. Modelo Estratégico ME15 (R)

## Modelo Estratégico 2014 – Conjunto Teste 2015

Dados 2015											Modelo Estratégico 2014 - Coni. Teste 2015																	
x <sub>0</sub>	x <sub>1</sub>	x <sub>2</sub>	x <sub>3</sub>	x <sub>4</sub>	x <sub>5</sub>	x <sub>6</sub>	x <sub>7</sub>	x <sub>8</sub>	x <sub>9</sub>	x <sub>10</sub>	y	RPropm	RPropp	SAG	RPropAvg	AVG6	RPropmQ	RProppQ	SAGQ									
-1	0	0	0	4	0	-6	-7	0	0	0	5	0.849	1.393	T	1.197	T	1.153	T	1.339	T	1.310	T	1.532	T	1.361	T	1.163	T
-1	0	0	0	8	8	-7	-6	0	0	6	7	0.990	0.931	T	0.955	T	0.991	T	0.966	T	0.942	T	1.023	T	0.894	T	0.885	T
-5	7	0	0	8	7	8	-8	8	0	0	8	1.035	0.792	T	1.232	T	1.041	T	1.060	T	0.933	T	1.159	T	1.207	T	0.942	T
0	6	0	0	9	0	0	0	0	0	0	0	1.029	1.169	T	1.613	T	1.357	T	1.169	T	1.216	T	1.522	T	1.482	T	1.104	T
0	5	3	7	0	0	-3	-5	0	6	4	6	1.129	1.046	T	1.047	T	1.056	T	1.131	T	1.179	T	1.091	T	1.156	T	1.204	T
-6	0	0	0	5	0	5	0	0	6	7	7	0.802	1.037	T	1.052	T	1.044	T	1.041	T	1.043	T	1.041	T	1.033	T	1.048	T
-7	0	0	0	0	0	-1	5	0	0	0	0	0.861	0.984	T	1.169	T	1.016	T	1.132	T	1.354	T	1.541	T	1.134	T	0.981	T
-3	5	3	1	3	3	3	3	3	4	0	0	0.914	0.828	T	0.835	T	0.871	T	0.837	T	0.822	T	0.823	T	0.833	T	0.865	T
0	4	3	0	9	5	9	-9	0	6	0	8	1.135	1.260	T	1.249	T	1.249	T	1.247	T	1.247	T	1.247	T	1.247	T	1.247	T
7	-5	5	0	7	0	-5	0	7	0	0	0	0.730	1.289	T	1.429	T	0.803	T	1.275	T	1.328	T	1.531	T	1.636	T	1.729	T
0	0	7	7	6	0	-8	7	8	7	7	7	1.171	1.160	T	1.147	T	1.060	T	1.131	T	1.383	T	1.143	T	1.107	T	1.147	T
-6	-5	0	6	0	0	0	0	7	0	6	5	1.119	0.946	T	0.947	T	0.947	T	0.947	T	0.950	T	0.947	T	0.946	T	0.948	T
-3	0	0	3	4	0	-4	-3	0	0	0	0	1.024	1.116	T	1.185	T	1.141	T	1.187	T	1.023	T	1.075	T	1.359	T	1.109	T
0	4	3	5	0	0	-1	0	0	0	0	4	1.716	1.303	T	1.297	T	1.408	T	1.320	T	1.270	T	1.211	T	1.155	T	1.280	T
2	2	0	2	6	3	-4	-0	0	0	4	3	1.015	1.260	T	1.173	T	1.207	T	1.206	T	1.196	T	1.198	T	1.343	T	1.209	T
2	5	0	3	3	-6	-7	0	4	0	0	0	0.953	0.928	T	1.088	T	1.035	T	0.918	T	0.904	T	0.909	T	0.836	T	0.880	T
-3	-3	-2	4	9	-4	-7	-7	4	4	4	7	1.074	1.099	T	1.118	T	1.112	T	1.126	T	1.111	T	1.116	T	1.110	T	1.106	T
6	7	0	5	4	5	-6	6	2	6	3	3	1.452	1.206	T	1.217	T	1.207	T	1.205	T	1.219	T	1.210	T	1.242	T	1.203	T
-8	0	0	8	5	0	-4	-6	7	7	8	8	0.956	0.915	T	1.364	T	1.222	T	1.117	T	1.037	T	1.179	T	1.096	T	1.119	T
-1	-1	2	5	2	-5	-7	0	8	3	6	6	0.986	0.913	T	0.706	T	1.058	T	0.965	T	0.951	T	1.087	T	1.109	T	1.015	T
-2	6	0	8	0	7	-7	-7	7	8	0	0	1.155	0.946	T	0.925	T	0.718	T	0.888	T	1.025	T	0.998	T	0.998	T	1.011	T
0	5	0	6	0	6	-9	-9	9	0	0	0	1.055	1.236	T	1.235	T	1.234	T	1.236	T	1.236	T	1.236	T	1.234	T	1.240	T
0	9	0	6	0	-4	-7	7	9	0	0	0	0.756	0.990	T	0.987	T	0.991	T	0.995	T	0.981	T	0.977	T	0.984	T	0.992	T
3	5	0	5	6	-7	-5	0	3	7	7	7	1.035	1.075	T	0.975	T	1.063	T	1.136	T	1.148	T	1.023	T	1.019	T	1.167	T
0	-5	5	6	0	5	5	0	5	0	7	7	0.789	1.167	T	0.918	T	1.835	T	1.008	T	1.414	T	1.206	T	1.685	T	1.095	T
0	2	0	2	0	3	3	0	2	0	0	0	1.013	1.049	T	1.209	T	1.023	T	0.880	T	1.046	T	1.177	T	1.118	T	1.014	T
-5	2	2	4	0	6	-5	5	4	7	8	7	1.200	0.886	T	1.077	T	0.996	T	0.981	T	1.007	T	0.981	T	0.891	T	0.938	T
0	5	0	4	4	-7	0	5	0	0	0	0	1.085	0.990	T	0.978	T	0.966	T	0.943	T	0.983	T	0.952	T	1.047	T	1.038	T
5	3	8	5	8	0	8	0	9	9	4	4	1.285	1.148	T	1.338	T	1.373	T	1.276	T	1.266	T	1.302	T	1.274	T	1.279	T
0	0	4	7	7	0	-5	-8	3	4	3	4	0.944	1.347	T	1.346	T	1.347	T	1.345	T	1.345	T	1.344	T	1.348	T	1.343	T
-2	0	0	0	0	9	-7	-2	5	2	8	1.205	0.563	T	1.011	T	0.788	T	0.820	T	0.753	T	0.696	T	0.972	T	0.927	T	
8	8	0	8	0	0	0	5	2	0	0	0	1.244	1.290	T	1.208	T	1.449	T	1.167	T	1.328	T	1.473	T	1.319	T	1.227	T

# ANEXOS- Resultados Experimentais

Dados 2015											Modelo Estratégico 2014 - Conj. Teste 2015									
0	1	2	3	4	5	6	7	8	9	10	y	RPropm	RPropp	SAG	RPropAvg	AVG6	RPropmQ	RPropmQ	SAGQ	
0	8	0	8	0	8	-7	3	6	5	7	0.987	1.112	1.249	1.047	1.192	1.073	1.206	1.092	1.144	
0	0	0	0	0	-7	0	0	8	0	0	1.166	0.919	1.118	0.983	1.109	1.319	0.837	0.368	1.071	
-4	9	0	8	0	-9	-1	0	0	0	2	1.171	1.241	1.241	1.240	1.242	1.242	1.244	1.247	1.247	
5	5	0	0	0	9	-9	6	9	0	9	0.601	1.142	1.274	1.253	1.295	1.065	1.056	1.306	1.086	
-4	5	0	0	0	5	0	8	5	0	5	1.128	1.348	1.157	1.314	1.162	1.112	1.047	1.158	1.009	
-4	-7	9	9	0	-6	6	2	7	2	3	1.104	1.559	1.007	1.598	0.941	1.117	1.131	0.909	1.290	
0	6	0	6	0	6	0	6	8	0	0	1.033	1.068	1.237	1.092	1.106	1.306	1.286	1.252	1.113	
1	1	0	7	0	0	-2	2	0	0	2	0.899	1.196	1.109	1.200	1.354	1.179	1.404	0.890	0.910	
-9	-8	1	8	5	0	0	7	0	8	7	1.228	0.795	0.842	0.836	1.023	0.918	1.081	0.990	0.893	
-5	0	0	3	4	-4	-8	0	0	4	9	1.004	1.165	1.083	0.709	0.838	1.134	1.258	0.973	1.005	
0	0	0	0	0	0	0	0	9	9	9	1.111	0.815	1.168	1.131	1.144	1.071	1.193	1.290	0.922	
0	7	0	8	6	-6	-7	0	4	5	6	1.025	1.079	1.009	1.159	1.168	0.980	1.019	0.996	0.886	
-7	0	7	2	4	2	6	5	6	3	7	1.712	0.794	1.151	1.198	1.140	1.112	0.852	0.899	1.140	
5	0	5	0	0	-5	-5	6	6	5	5	1.044	1.001	0.861	1.006	0.831	1.251	0.970	0.884	0.684	
5	5	0	8	0	6	0	5	4	0	5	1.142	1.191	0.831	1.027	1.083	0.938	1.104	0.928	0.849	
-5	-5	5	5	5	5	5	5	5	0	5	0.994	1.084	1.030	1.084	1.056	1.081	1.059	1.061	1.092	
4	9	0	8	0	0	0	9	0	0	1	1.422	1.004	2.019	1.065	1.064	1.225	1.197	0.824	1.101	
2	-2	0	0	1	2	2	3	2	0	4	0.938	1.064	0.884	0.881	0.959	0.952	1.198	0.935	1.405	
2	3	0	0	4	-4	0	0	3	0	2	1.000	0.986	0.987	0.983	0.988	0.981	0.990	0.994	0.992	
0	0	1	2	5	7	-7	0	7	1	1	0.974	1.212	0.826	0.912	1.063	1.170	1.016	0.902	1.056	
-6	3	0	2	0	2	-4	0	0	1	2	1.156	0.943	0.987	0.966	0.967	0.961	0.964	0.963	0.963	
5	-5	0	6	0	6	8	0	9	0	9	1.026	1.392	1.396	2.565	1.075	1.338	1.453	1.861	1.189	
-6	0	4	4	4	6	-6	7	3	3	6	1.018	0.987	0.982	1.030	0.975	1.065	1.072	1.047	0.949	
-7	7	1	0	3	8	-8	8	5	5	7	1.151	0.986	1.088	1.311	1.134	1.006	1.039	1.087	0.925	
-5	7	5	7	6	-6	-6	6	7	6	1	1.015	1.024	1.107	1.067	1.043	1.033	1.069	1.104	1.112	
-6	-2	0	8	0	-8	-9	8	7	8	0	0.848	1.532	1.748	1.288	1.156	1.219	1.181	1.377	1.197	
-6	-5	0	5	0	-4	-3	0	4	5	0	0.947	1.078	1.009	0.995	1.083	1.019	1.016	1.089	1.050	
2	6	0	9	0	7	-6	5	1	9	7	0.914	1.125	1.289	1.264	1.534	1.238	1.343	1.466	1.254	
0	7	2	6	0	-7	-6	5	6	6	0	1.125	1.060	0.897	0.848	0.992	0.979	0.907	0.995	0.849	
1	4	0	3	0	-5	-8	0	7	8	7	0.978	0.333	0.842	0.724	0.887	0.830	0.740	0.867	0.917	
6	5	0	6	0	-6	-6	0	7	5	7	1.165	0.505	1.985	1.149	1.409	1.264	1.233	0.939	1.836	
0	9	0	4	0	-1	-3	0	0	0	0	0.970	1.081	1.239	1.324	1.145	1.165	1.532	0.445	1.284	
0	0	0	6	0	0	0	0	2	0	6	1.329	1.159	1.142	1.316	1.298	1.075	1.192	0.989	1.091	
3	7	0	8	0	-8	0	7	3	9	5	1.043	1.156	1.298	0.983	0.978	1.232	1.091	1.228	1.091	
-1	0	0	4	9	-9	-8	9	8	9	5	1.053	1.058	1.165	0.854	0.918	0.985	1.035	1.079	1.023	
0	8	0	2	0	-8	-3	4	6	8	4	0.996	1.101	0.935	0.786	0.909	0.854	0.635	0.903	1.011	
-3	6	0	0	7	6	-6	2	5	0	0	0.889	1.119	1.132	0.937	1.106	1.082	1.071	1.044	1.048	
0	0	0	3	0	-2	-3	6	3	2	4	1.080	1.260	1.279	1.294	1.205	1.155	1.041	1.151	1.203	
-3	6	1	4	0	7	7	0	0	6	7	1.054	0.942	1.080	0.886	0.945	0.941	1.101	0.837	1.166	
-4	4	0	4	5	4	-5	0	0	5	5	1.286	0.980	1.017	0.967	0.961	0.974	0.981	0.995	0.985	
-5	0	0	6	8	-5	-7	0	5	0	0	1.306	1.054	1.078	1.049	1.062	1.037	1.056	1.003	1.037	
-7	8	0	8	0	9	0	0	7	7	7	1.029	1.135	1.345	1.097	0.892	1.314	1.264	1.071	1.095	
0	0	0	7	0	-7	-8	7	7	7	0	1.275	1.120	1.026	1.104	1.010	1.048	1.074	1.081	1.074	
-7	-7	0	0	0	0	0	0	0	0	0	1.106	1.303	1.516	1.421	1.327	1.299	1.278	1.254	1.214	
5	5	0	5	0	-5	-5	5	5	5	9	1.192	1.148	1.154	1.149	1.145	1.156	1.144	1.175	1.140	
3	6	2	5	8	-8	-8	0	4	3	6	1.221	1.099	1.041	1.092	1.128	1.142	1.073	0.919	0.931	
3	4	0	4	3	5	-4	3	5	5	4	1.024	1.287	1.293	1.284	1.289	1.261	1.251	1.232	1.270	
5	5	0	5	5	-5	-5	0	5	6	9	1.229	1.058	1.401	1.262	1.272	1.331	1.144	1.279	1.186	
8	5	0	0	0	7	0	7	0	8	0	1.187	0.799	1.254	1.176	0.988	0.997	1.486	0.849	1.166	
5	7	0	4	0	-6	-6	5	4	0	0	1.002	1.120	1.432	1.180	1.147	1.429	1.413	1.328	1.438	
2	0	4	0	0	-6	-1	6	7	0	6	0.916	0.701	0.895	0.958	0.995	0.886	0.953	0.906	0.898	
0	5	0	5	0	0	0	0	0	0	3	1.284	1.480	1.128	1.259	1.209	1.227	1.260	1.293	1.288	
-5	5	0	4	0	9	-7	4	7	7	0	1.035	1.135	0.636	0.610	1.117	0.997	0.933	0.943	1.097	
0	0	0	7	0	0	-6	7	8	0	0	1.174	0.928	0.894	0.959	0.911	0.975	0.972	0.938	0.968	
-5	7	0	0	4	6	-7	7	7	0	0	1.313	1.128	1.025	1.526	1.086	1.064	1.047	1.073	1.006	
-3	0	0	4	0	0	-4	3	5	0	0	1.156	1.023	1.074	0.985	1.183	1.101	0.819	1.042	0.968	
-6	6	5	7	0	0	-7	3	4	7	7	1.288	1.088	1.140	1.269	1.100	1.169	1.051	1.129	1.097	
-7	7	0	5	0	0	-8	0	8	0	6	1.064	0.995	0.963	0.974	0.998	0.967	0.967	0.937	0.958	
0	4	0	5	0	-5	-6	5	6	5	5	1.585	1.147	0.876	0.877	1.031	0.864	0.786	0.934	0.807	
1	4	0	8	0	7	-6	4	6	1	6	0.770	1.164	1.009	1.085	0.996	1.026	1.073	1.139	1.030	
5	6	0	6	0	6	-5	2	4	0	4	1.163	0.780	0.781	0.779	0.779	0.784	0.784	0.779	0.778	
3	0	0	5	3	-5	-6	7	6	6	6	1.389	1.292	1.197	1.067	1.184	1.122	0.921	1.091	1.203	
1	1	0	8	0	7	0	5	7	0	0	1.127	1.094	0.775	1.258	1.238	1.195	1.384	1.010	1.020	
0	8	0	7	8	-8	-8	6	7	2	7	1.283	0.945	0.867	0.980	0.948	0.817	0.984	0.907	0.988	
0	0	7	0	0	-6	-8	9	7	0	9	1.143	0.244	1.008	0.951	1.036	1.001	1.275	0.915	1.026	
0	5	0	8	2	7	-7	8	4	7	5	1.186	0.953	1.163	1.214	1.309	1.167	1.261	1.292	1.194	
0	5	0	2	0	0	0	0	3	3	0	1.074	1.105	1.154	1.197	1.045	0.977	1.350	0.927	1.195	
0	0	0	2	0	-3	0	2	4	0	3	1.355	1.176	1.141	1.160	1.074	0.991	1.111	1.127	0.922	
8	7	0	0	9	2	0	0	7	5	3	1.169	0.827	1.289	0.973	0.943	1.340	1.039	1.142	0.981	
0	0	0	0	0	0	-5	1	8	8	8	1.100	0.976	0.979	1.071	1.079	0.991	0.876	1.068	0.993	
-5	5	0	7	0	-9	-7	7	3	6	8	1.918	1.296	1.171	1.321	1.182	1.044	1.150	1.238	1.256	
0	8	0	0	0	7	-9	8	0	8	9	1.213	0.936	1.523	1.348	1.094	1.202	1.213	1.286	1.247	
4	8	0	2	0	-6	-7	0	3	0	5	1.752	1.020	1.402	1.593	1.261	1.245	1.666	1.000	0.952	
7	7	0	7	0	7	0	7	0	0	0	1.009	1.074	1.216	1.229	1.168	1.490	1.004	1.292	1.245	
0	5	0	0	0	5	-5														



# ANEXOS- Resultados Experimentais

Dados 2015											Modelo Estratégico 2014 - Coni. Teste 2015												
x <sub>0</sub>	x <sub>1</sub>	x <sub>2</sub>	x <sub>3</sub>	x <sub>4</sub>	x <sub>5</sub>	x <sub>6</sub>	x <sub>7</sub>	x <sub>8</sub>	x <sub>9</sub>	x <sub>10</sub>	y	RPropm	RProp	SAG	RPropAvg	AVG6	RPropmQ	RPropQ	SAGQ				
1	6	0	1	0	7	-8	2	8	0	6	1.237	1.238	T	1.221	T	1.239	T	1.250	T	1.212	T	1.277	T
0	8	0	0	0	7	-7	0	8	0	0	0.792	0.992	T	0.993	T	0.992	T	0.994	T	0.987	T	0.992	T
5	7	0	5	4	-4	0	8	8	5	7	1.118	0.456	T	0.953	T	1.016	T	0.993	T	1.032	T	0.940	T
-5	6	2	7	1	-7	0	0	6	7	7	1.018	1.367	T	1.931	T	1.466	T	1.329	T	1.507	T	1.466	T
2	2	0	4	0	5	3	5	8	6	0	1.033	1.100	T	1.013	T	0.859	T	1.084	T	1.206	T	1.336	T
5	8	0	5	0	0	0	0	0	0	5	1.520	1.026	T	1.580	T	1.333	T	1.217	T	1.340	T	0.970	T
-3	-5	2	3	3	-5	-5	5	5	1	3	0.915	1.004	T	1.183	T	1.070	T	1.118	T	0.974	T	1.062	T
-2	0	0	2	0	6	-3	0	0	0	0	1.141	1.226	T	1.513	T	0.834	T	0.948	T	0.716	T	1.079	T
0	7	6	0	5	-5	-3	0	3	6	1.040	1.038	T	1.073	T	1.143	T	1.091	T	1.005	T	1.086	T	
5	5	0	0	4	7	-5	4	2	0	4	1.600	1.277	T	1.068	T	1.267	T	1.347	T	1.334	T	1.010	T
6	7	0	3	0	7	0	0	7	2	8	0.957	1.155	T	1.221	T	1.061	T	1.008	T	1.120	T	1.236	T
4	5	7	7	5	5	-2	2	6	3	1.017	1.683	T	1.262	T	1.133	T	1.259	T	1.319	T	1.237	T	
-3	3	0	1	0	-5	-4	0	4	3	4	1.071	1.156	T	1.032	T	1.213	T	0.999	T	1.129	T	1.289	T
-5	9	0	7	0	0	-9	0	9	0	9	1.259	1.080	T	1.126	T	0.958	T	1.096	T	1.095	T	1.092	T
6	7	0	3	0	-7	-7	6	2	0	0	1.069	1.903	T	1.277	T	2.325	T	1.465	T	1.803	T	1.379	T
-4	0	0	7	0	-7	-8	7	6	4	7	1.149	1.161	T	1.086	T	1.240	T	1.214	T	1.164	T	1.210	T
5	5	0	0	0	0	-4	3	0	0	0	1.121	1.380	T	1.197	T	1.475	T	1.340	T	1.221	T	1.443	T
6	7	0	8	0	7	-9	0	7	7	7	1.373	0.770	T	1.083	T	0.908	T	1.111	T	1.150	T	1.045	T
9	0	5	6	8	-6	-8	1	7	0	9	1.094	1.379	T	1.379	T	1.025	T	1.277	T	1.659	T	1.215	T
-7	6	0	1	3	4	-6	7	5	0	5	1.295	0.979	T	1.064	T	1.344	T	1.052	T	1.044	T	1.065	T
2	3	0	3	0	5	-4	0	4	0	0	1.561	1.041	T	0.898	T	1.061	T	1.003	T	1.030	T	1.087	T
0	7	0	4	0	6	0	3	0	0	0	1.792	1.400	T	1.288	T	1.241	T	1.287	T	1.323	T	1.492	T
4	4	0	1	0	7	0	0	3	0	0	0.960	0.993	T	1.156	T	1.200	T	1.065	T	0.836	T	1.161	T

Tabela A-45: Redes Neurais R - Resultados Dados 2015. Modelo Estratégico ME14T15 (R)

## Modelo Estratégico Global

Dados 2015											Modelo Estratégico Global (2013-2014-2015)																
x <sub>0</sub>	x <sub>1</sub>	x <sub>2</sub>	x <sub>3</sub>	x <sub>4</sub>	x <sub>5</sub>	x <sub>6</sub>	x <sub>7</sub>	x <sub>8</sub>	x <sub>9</sub>	x <sub>10</sub>	y	RPropm	RPropp	SAG	RPropAvg	AVG6	RPropmQ	RPropQ	T	SAGQ							
-1	0	0	4	0	-6	-7	0	0	4	5	0.849	0.848	P	0.847	P	0.848	P	0.851	P	0.846	P	1.565	T	1.509	T	1.349	T
-1	0	0	8	8	-7	-6	0	0	6	7	0.990	0.994	P	0.990	P	0.990	P	0.991	P	0.992	P	1.147	T	1.304	T	0.961	T
-5	7	0	8	7	8	-8	8	0	0	8	1.035	1.037	P	1.035	P	1.034	P	1.035	P	1.026	P	1.035	P	1.036	P	1.034	P
0	6	0	9	0	0	0	0	0	0	0	1.029	1.028	P	1.030	P	1.028	P	1.028	P	0.999	T	0.420	T	0.977	T	0.974	T
0	5	3	7	0	-3	-5	0	6	4	6	1.129	1.122	P	1.125	P	1.124	P	1.122	P	1.118	P	1.130	P	1.126	P	1.128	P
-6	0	0	5	0	5	0	0	6	0	7	0.902	0.965	T	0.954	T	0.774	T	0.970	T	0.791	T	0.974	T	0.974	T	0.974	T
-7	0	0	0	0	0	-1	5	0	0	0	0.961	1.105	T	1.180	T	2.884	T	1.144	T	1.105	T	0.961	P	0.963	P	0.961	P
-3	5	3	1	3	3	3	3	3	4	0	0.914	0.924	P	0.913	P	0.918	P	0.913	P	0.923	P	0.916	P	0.921	P	0.909	P
0	9	0	9	5	9	-9	0	6	0	8	1.135	1.193	P	1.193	P	1.193	P	1.193	P	1.188	P	1.191	P	1.191	P	1.194	P
7	-5	5	0	7	0	-5	0	7	0	0	0.730	1.210	T	1.000	T	1.408	T	1.260	T	0.978	T	0.731	P	0.731	P	0.729	P
0	0	7	7	6	0	-8	7	8	6	7	1.171	1.087	T	1.325	T	1.158	T	1.231	T	1.258	T	1.171	P	1.176	P	1.172	P
-6	-5	0	6	0	0	0	7	0	6	5	1.119	1.026	P	1.027	P	1.029	P	1.026	P	1.027	P	1.028	P	1.028	P	1.027	P
-3	0	0	3	4	0	-4	3	0	0	0	1.024	1.024	P	1.024	P	1.025	P	1.022	P	1.023	P	1.025	P	1.024	P	1.024	P
0	4	3	5	0	0	-1	0	0	4	4	1.716	1.362	T	1.421	T	1.349	T	1.397	T	1.316	T	1.330	T	1.003	T	1.343	T
2	2	0	2	6	3	-4	0	0	4	3	1.015	1.007	P	1.017	P	1.011	P	1.004	P	1.018	P	1.013	P	1.015	P	1.015	P
2	5	0	3	3	-6	-7	0	4	0	0	0.953	0.993	T	0.876	T	0.904	T	0.935	T	0.940	T	1.074	T	1.401	T	1.022	T
-3	-3	2	4	9	-4	-7	7	4	4	7	1.074	1.065	P	1.075	P	1.076	P	1.072	P	1.104	P	1.099	P	1.094	P	1.077	P
6	7	0	5	4	5	-6	6	2	6	3	1.452	1.334	P	1.329	P	1.329	P	1.331	P	1.331	P	1.299	P	1.296	P	1.296	P
-8	0	0	8	5	0	-4	6	7	7	8	0.956	0.958	P	0.957	P	0.957	P	0.958	P	0.951	P	0.953	P	0.956	P	0.955	P
-1	-1	2	5	2	-5	-7	0	8	3	6	0.986	0.923	T	1.025	T	1.315	T	0.983	T	0.999	T	0.982	P	0.973	P	0.984	P
-2	6	0	8	0	7	-7	7	8	0	0	1.155	1.334	T	1.047	T	0.892	T	1.175	T	0.968	T	1.155	P	1.154	P	1.155	P
0	5	4	0	6	-9	-9	9	0	0	0	1.055	0.761	T	0.759	T	0.759	T	0.761	T	0.759	T	0.762	T	0.759	T	0.758	T
0	9	0	6	0	-4	-7	7	9	0	0	0.756	0.979	P	0.979	P	0.980	P	0.979	P	0.978	P	0.979	P	0.978	P	0.979	P
3	5	0	5	6	-7	-5	0	3	7	7	1.035	1.038	P	1.034	P	1.037	P	1.035	P	1.034	P	1.030	P	1.032	P	1.036	P
0	-5	5	6	0	5	0	5	0	0	7	0.789	0.788	P	0.787	P	0.790	P	0.787	P	0.788	P	2.351	T	0.801	T	0.986	T
0	2	0	2	0	3	3	0	2	0	0	1.013	1.296	T	1.294	T	1.297	T	1.294	T	1.293	T	1.296	T	1.296	T	1.295	T
-5	2	2	4	0	6	-5	5	4	7	8	1.200	1.198	P	1.198	P	1.198	P	1.193	P	1.188	P	1.187	P	1.181	P	1.186	P
0	0	0	4	4	-7	0	5	0	0	0	1.085	0.886	T	0.944	T	0.970	T	0.904	T	0.996	T	1.084	P	0.983	P	0.983	P
5	8	1	8	5	8	0	9	9	4	4	1.285	1.283	P	1.288	P	1.285	P	1.287	P	1.288	P	1.309	P	1.298	P	1.293	P
0	0	4	7	0	-5	-8	3	4	3	4	0.944	0.941	P	0.944	P	0.940	P	0.956	P	0.952	P	1.143	P	1.145	P	1.143	P
-2	0	0	0	0	9	-7	-2	5	2	8	1.205	1.203	P	1.204	P	1.205	P	1.204	P	1.206	P	1.203	P	1.203	P	1.205	P
8	8	0	8	0	0	5	2	0	0	0	1.244	1.243	P	1.245	P	1.242	P	1.243	P	1.244	P	1.245	P	1.245	P	1.244	P
0	8	0	8	0	8	-7	3	6	5	7	0.987	0.977	P	0.998	P	0.988	P	0.989	P	0.997	P	0.985	P	0.980	P	0.986	P
0	0	0	0	0	-7	0	0	8	0	0	1.166	0.916	T	0.941	T	1.244	T	0.942	T	0.662	T	1.167	P	1.165	P	1.165	P
-4	9	0	8	0	-9	-1	0	0	0	2	1.171	1.206	P	1.207	P	1.207	P	1.208	P	1.207	P	1.171	P	1.171	P	1.171	P
5	5	0	0	0	9	-9	6	9	0	9	0.601	0.601	P	0.601	P	0.600	P	0.601	P	0.601	P	0.600	P	0.600	P	0.600	P
-4	5	0	0	0	5	0	8	5	0	5	1.128	1.119	P	1.128	P	1.128	P	1.125	P	1.129	P	1.127	P	1.128	P	1.128	P
-4	-7	9	9	0	-6	6	2	7	2	3	1.104	1.105	P	1.105	P	1.105	P	1.102	P	1.103	P	1.104	P	1.104	P	1.104	P
0	6	0	6	0	6	0	6	8	0	0	1.033	0.994	T	1.060	T	0.927	T	1.038	T	1.123	T	1.226	T	1.231	T	1.176	T
1	1	0	7	0	0	-2	2	0	0	2	0.899	0.899	P	0.903	P	0.898	P	0.900	P	0.902	P	0.898	P	0.900	P	0.899	P
-9	-8	1	8	5	0	0	7	0	8	7	1.228	0.695	T	0.597	T	1.029	T	0.638	T	0.709	T	1.027	T	0.752	T	0.997	T
-5	0	0	3	4	-4	-8	0	0	4	9	1.004	1.006	P	1.004	P	1.004	P	1.002	P	1.006	P	1.001	P	1.002	P	1.004	P
0	0	0	0	0	0	0	0	9	9	9	1.111	1.110	P	1.113	P	1.109	P	1.109	P	1.111	P	1.113	T	1.248	T	0.958	T
0	7	0	8	6	-6	-7	0	4	5	6	1.025	1.021	P	1.026	P	1.027	P	1.030	P	1.021	P	1.028	P	1.032	P	1.023	P
-7	0	7	2	4	2	2	6	5	6	3	7	1.712	1.047	T	1.050	T	1.174	T	1.055	T	1.010	T	1.712	P	1.712	P	
5	0	5	0	0	-5	-5	6	6	5	5	1.044	1.041	P	1.203	T	1.145	T	1.100	T	1.368	T	1.044	P	1.043	P	1.045	P
5	5	0	8	0	6	0	5	4	0	5	1.142	1.139	P	1.141	P	1.142	P	1.142	P	1.138	P	1.127	P	1.072	P	0.668	T
-5	-5	5	5	5	5	5	5	5	0	5	0.994	0.864	T	0.840	T	0.885	T	0.846	T	0.977	T	1.572	T	1.312	T	1.272	T
4	9	0	8	0	0	0	9	0	0	0	1.427	1.427	P	1.422	P	1.420	P	1.427	P	1.421	P	1.421	P	1.422	P	1.422	P
4	9	0	8	0	0	0	9	0	0	0	1.428	1.041	T	0.965	T	1.033	T	1.033	T	1.053	T	0.938	T	0.938	T	0.938	T
0	0	4	4	0	-4	0	0	3	0	2	1.000	1.142	T	0.921	T	1.304	T	1.049	T	0.552	T	0.980	P	0.981	P	0.980	P
0	0	1	2	5	7	-7	0	7	1	1	0.974	1.033	T	1.054	T	0.972	T	1.042	T	0.932	T	0.945	T	0.997	T	1.049	T
-6	3	0	2	0	2	-4	0	0	1	2	1.156	1.206	T	1.123	T	0.978	T	1.180	T	1.136	T	1.062	P	1.063	P	1.061	P
5	-5	0	6	0	6	8	0	9	0	9	1.026	0.897	T	1.268	T	1.194	T	1.070	T	1.379	T	1.026	P	1.027	P	1.024	P
-6	0	4	4	4	6	-6	7	3	3	6	1.018	1.010	P	1.016	P	1.018	P	1.016	P	1.014	P	1.023	P	1.016	P	1.019	P
-7	7	1	0	3	8	-8	8	5	5	7	1.151	1.163	T	0.957	T	1.191	T	1.032	T	1.207	T	1.153	P	1.156	P	1.151	P
-5	7	5	7	6	-6	-6	6	7	6	1	1.015	1.449	T	1.050	T	0.988	T	1.225	T	1.055	T	1.024	P	1.016	P	1.012	P
-6	-2	0	8	0	-8	-9	8	7	8	0	0.848	0.802	T	0.468	T	0.804	T	0.586	T	0.945	T	0.846	P	0.848	P	0.847	P
-6	-5	0	5	0	-4	-3	0	4	5	0	0.947	0.948	P	0.946	P	0.946	P	0.948	P	0.951	P	1.092	T	1.076	T	1.077	T
2	6	0	9	0	7	-6	5	1	9	7	0.914	0.916	P	0.915	P	0.914	P	0.917	P	0.916	P	1.691	T	1.423	T	1.474	T
0	7	2	6	0	-7	-6	5	6	6	0	1.125	1.125	P	1.126	P	1.128	P	1.112	P	1.122	P						



# ANEXOS- Resultados Experimentais

Dados 2015											Modelo Estratégico Global (2013-2014-2015)										
0	1	2	3	4	5	6	7	8	9	10	y	RPropm	RPropp	SAG	RPropAvg	AVG6	RPropmQ	RProppQ	SAGQ		
0	0	0	7	0	-7	-8	7	7	7	0	1.275	1.135	T	0.488	T	1.215	T	1.197	P	1.188	P
-7	-7	0	0	0	0	0	0	0	0	0	1.106	1.294	T	1.172	T	1.230	T	1.107	P	1.106	P
5	5	0	5	0	-5	-5	5	5	5	9	1.192	1.140	P	1.139	P	1.135	P	1.115	T	1.119	T
3	6	2	5	8	-8	-8	0	4	3	6	1.221	1.058	T	1.148	T	1.102	T	1.078	T	0.997	T
3	4	0	4	3	5	-4	3	5	5	4	1.024	1.143	T	1.175	T	1.123	T	1.119	T	1.064	P
5	5	0	5	5	-5	-5	0	5	6	9	1.229	1.231	P	1.230	P	1.227	P	1.231	P	1.231	P
8	5	0	0	0	7	0	7	0	8	0	1.187	1.188	P	1.188	P	1.191	P	1.186	P	1.187	P
5	7	0	4	0	-6	0	5	4	0	0	1.002	1.000	P	1.003	P	1.006	P	1.002	P	0.999	P
-7	7	0	5	0	0	-8	0	8	0	6	1.064	1.408	T	0.890	T	1.090	T	1.145	T	0.919	P
0	5	0	5	0	5	0	0	0	3	1.284	1.579	T	1.331	T	1.476	T	1.459	T	1.643	T	
-5	5	0	4	0	9	-7	4	7	7	0	1.035	1.034	P	1.033	P	1.034	P	1.035	P	1.036	P
0	0	0	7	0	0	-6	7	8	0	0	1.174	1.174	P	1.164	P	1.173	P	1.160	P	1.172	P
-5	7	0	0	4	6	-7	7	7	0	0	1.313	1.312	P	1.313	P	1.315	P	1.316	P	1.312	P
-3	0	0	4	0	0	-4	3	5	0	0	1.156	1.159	P	1.157	P	1.160	P	1.159	P	1.157	P
-6	6	5	7	0	0	-7	3	4	7	7	1.288	1.286	P	1.295	P	1.293	P	1.291	P	1.211	T
-7	7	0	5	0	0	-8	0	8	0	6	1.064	1.059	P	1.042	P	1.040	P	1.039	P	1.034	P
0	4	0	5	0	-6	-5	6	6	5	1.585	1.587	P	1.593	P	1.583	P	1.583	P	1.576	P	
1	4	0	8	0	7	-6	4	6	1	6	0.770	0.770	P	0.772	P	0.768	P	0.766	P	0.770	P
5	6	0	6	0	6	-5	2	4	0	4	1.163	1.218	P	1.217	P	1.215	P	1.212	P	0.781	T
3	0	0	5	3	-5	-6	7	6	6	6	1.389	1.388	P	1.389	P	1.396	P	1.391	P	1.396	P
1	1	0	8	0	7	0	5	7	0	0	1.127	0.822	T	1.331	T	1.083	T	1.071	T	1.128	P
0	8	0	7	8	-8	-6	7	2	7	1.283	1.281	P	1.282	P	1.282	P	1.284	P	1.286	P	
0	0	7	0	0	-6	-8	9	7	0	9	1.143	1.155	T	1.196	T	1.170	T	1.067	T	1.143	P
0	5	0	8	2	7	-7	8	4	7	5	1.186	1.185	P	1.187	P	1.189	P	1.185	P	1.176	T
0	5	0	2	0	0	0	0	3	3	0	1.074	1.086	P	1.054	P	1.073	P	1.074	P	1.073	P
0	0	0	2	0	-3	0	2	4	0	3	1.355	1.366	P	1.346	P	1.365	P	1.362	P	1.356	P
8	7	0	0	9	2	-9	0	7	5	9	1.169	1.168	P	1.167	P	1.169	P	1.165	P	1.170	P
0	0	0	0	0	0	-5	1	8	8	8	1.100	1.102	P	1.099	P	1.102	P	1.101	P	0.934	T
-5	5	0	7	0	-9	-7	7	3	6	8	1.918	1.919	P	1.918	P	1.917	P	1.918	P	1.916	P
0	8	0	0	0	7	-9	8	0	8	9	1.213	1.209	P	1.214	P	1.211	P	1.213	P	1.212	P
4	8	0	2	0	-6	-7	0	3	0	5	1.752	1.752	P	1.751	P	1.752	P	1.751	P	1.750	P
7	7	0	7	0	7	0	7	0	0	0	1.009	1.011	T	1.318	T	1.582	T	1.181	T	1.218	T
0	5	0	0	0	5	-5	5	0	5	0	1.221	0.990	T	1.024	T	1.307	T	1.004	T	1.039	T
-5	0	0	0	0	0	-9	8	0	8	0	0.658	1.012	T	1.028	T	1.110	T	1.047	T	0.657	P
5	9	0	8	0	6	0	0	0	9	0	1.038	1.606	T	1.030	T	1.289	T	1.312	T	1.254	T
5	9	0	0	0	9	-5	5	9	3	0	1.088	1.089	P	1.090	P	1.087	P	1.088	P	1.082	P
6	9	0	6	5	-9	9	4	0	5	6	1.182	1.181	P	1.181	P	1.181	P	1.181	P	1.181	P
3	9	0	2	0	9	-3	9	5	0	5	1.138	1.139	P	1.136	P	1.138	P	1.135	P	1.135	P
5	9	0	5	0	-5	-9	0	0	5	5	1.897	1.898	P	1.900	P	1.894	P	1.900	P	1.899	P
0	-3	0	0	0	0	-3	0	0	0	4	0.974	0.965	T	0.925	T	1.114	T	0.935	T	1.054	T
0	0	0	0	0	9	-9	9	9	0	0	1.243	1.245	P	1.243	P	1.245	P	1.241	P	1.240	P
7	6	0	5	0	8	-5	5	0	0	0	1.269	1.310	T	1.622	T	1.332	T	1.468	T	1.184	T
-1	-1	0	0	0	-7	0	1	7	0	4	0.991	1.029	P	1.028	P	1.029	P	1.030	P	1.048	T
5	8	0	0	0	5	-5	0	0	0	0	0.957	0.954	P	0.957	P	0.957	P	0.955	P	0.957	P
3	7	0	5	0	3	0	0	0	0	0	1.822	1.824	P	1.821	P	1.822	P	1.828	P	1.820	P
-2	-1	7	0	1	0	-5	5	5	7	1.366	1.367	P	1.370	P	1.362	P	1.368	P	1.366	P	
-5	0	1	5	0	-9	-5	7	0	5	9	0.916	0.916	P	0.916	P	0.919	P	0.916	P	0.920	P
7	7	0	6	0	0	-6	0	0	0	6	1.485	1.030	P	1.031	P	1.028	P	1.029	P	1.028	P
-6	6	3	4	0	3	0	4	4	0	0	1.052	1.050	P	1.054	P	1.055	P	1.053	P	1.055	P
-7	8	5	5	7	7	-7	0	0	6	6	1.002	1.003	P	1.002	P	1.005	P	1.002	P	0.998	P
-8	6	3	8	5	0	-8	5	3	7	5	0.958	0.956	P	0.962	P	0.958	P	0.963	P	0.964	P
-2	7	0	4	0	-6	-4	0	0	2	4	1.032	1.034	P	1.033	P	1.033	P	1.039	P	0.964	P
0	0	0	5	4	-3	-1	0	2	0	0	1.200	0.789	T	0.888	T	1.087	T	0.839	T	0.727	T
-1	6	0	2	9	-9	-4	6	6	4	2	1.634	1.637	P	1.633	P	1.636	P	1.633	P	1.629	P
0	0	0	5	0	-7	0	8	7	0	8	0.994	0.996	P	0.993	P	0.994	P	0.999	P	1.338	T
0	0	0	0	0	-7	3	4	1	0	0	1.226	1.227	P	1.226	P	1.225	P	1.226	P	1.225	P
-6	-1	9	2	0	8	-6	0	0	8	9	0.765	0.769	P	0.765	P	0.764	P	0.765	P	0.767	P
0	9	0	8	0	6	-8	7	5	7	6	1.368	1.372	P	1.369	P	1.368	P	1.374	P	1.362	P
0	0	6	0	8	6	-5	8	6	6	5	0.655	0.657	P	0.656	P	0.655	P	0.658	P	0.657	P
6	7	0	0	0	-8	0	8	6	0	0	1.118	1.115	P	1.118	P	1.119	P	1.121	P	0.971	T
0	0	0	5	5	-5	-5	0	0	5	9	1.022	0.987	P	0.987	P	0.986	P	0.987	P	0.986	P
3	5	0	1	3	6	-4	1	0	0	2	0.796	0.801	P	0.795	P	0.797	P	0.801	P	0.795	P
-3	0	0	0	0	2	0	2	6	0	0	1.076	1.074	P	1.077	P	1.075	P	1.081	P	1.073	P
0	-6	0	0	0	0	-5	0	0	0	4	1.237	1.260	T	0.889	T	1.081	T	1.038	T	1.145	T
1	-2	0	5	3	-3	-3	1	0	5	3	1.010	1.005	P	1.008	P	1.008	P	1.005	P	1.012	P
4	6	4	6	5	8	-6	0	2	0	2	1.115	1.113	P	1.115	P	1.114	P	1.115	P	1.118	P
8	8	0	7	0	8	7	7	5	0	5	1.070	1.051	P	1.052	P	1.051	P	1.052	P	1.051	P
7	7	0	6	0	-6	-6	6	6	6	6	1.153	1.158	P	1.153	P	1.154	P	1.155	P	1.151	P
0	0	5	3	0	-6	3	0	6	3	4	1.117	1.117	P	1.117	P	1.120	P	1.117	P	1.118	P
1	6	0	1	0	7	-8	2	8	0	6	1.237	1.105	T	1.100	T	1.204	T	1.098	T	1.179	T
8	8	0	0	0	7	-7	0	8	0	0	0.792	0.895	P	0.892	P	0.894	P	0.892	P	0.893	P
5	7	0	5	4	-4	0	8	8	5	7	1.118	1.117	P	1.120	P	1.119	P	1.119	P	1.113	P
-5	6	2	7	1	-7	0	0	6	7	7	1.018	1.019	P	1.017	P	1.016	P	1.018	P	1.018	P
2	2	0	4	0	5	3	5	8	6	0	1.033	1.032	P	1.032	P	1.030	P	1.036	P	1.033	P
5	8	0	5	0	0	0	0	0	0	5	1.520	1.522	P	1.521	P	1.521	P	1.519	P	1.519	P
-3	-5	2	3	3	-5	-5	5	1	3	0.915	1.352	T	1.318	T	1.369	T	1.336	T	1.267	T	
-2	0	0	2	0	6	-3	0	0	0	0	1.141	1.144	P	1.141	P	1.139					

**Matriz de Desempenho**

			#Amostras								Soma
Modelo	Set	Algorithm	Erro<5%	Erro<10%	Erro<20%	Erro<30%	Erro<40%	Erro<50%	Erro>=50%	Total	Erros
ME13T14	Teste	Rprop+	31	63	114	140	154	160	18	178	37.730773
ME13T14	Treino	Rprop+	128	128	128	128	128	128	0	128	0.3319415
ME13T14	Teste	Rprop-	32	54	93	126	145	155	23	178	44.241543
ME13T14	Treino	Rprop-	127	128	128	128	128	128	0	128	0.6362891
ME13T14	Teste	SAG	26	61	101	137	158	163	15	178	38.855303
ME13T14	Treino	SAG	122	127	128	128	128	128	0	128	1.6372365
ME13T14	Teste	Rprop+/Q	40	66	113	142	156	162	16	178	36.292803
ME13T14	Treino	Rprop+/Q	127	128	128	128	128	128	0	128	0.4551889
ME13T14	Teste	Rprop-/Q	31	63	107	140	154	164	14	178	37.844073
ME13T14	Treino	Rprop-/Q	128	128	128	128	128	128	0	128	0.7886319
ME13T14	Teste	SAG/Q	38	75	113	133	154	167	11	178	35.96488
ME13T14	Treino	SAG/Q	127	127	128	128	128	128	0	128	0.5109479
ME13	Teste	Rprop+	6	13	24	32	33	33	5	38	9.0519753
ME13	Treino	Rprop+	87	90	90	90	90	90	0	90	0.9085354
ME13	Teste	Rprop-	7	10	20	29	32	35	3	38	8.1765638
ME13	Treino	Rprop-	89	90	90	90	90	90	0	90	0.4446541
ME13	Teste	SAG	5	10	21	28	31	33	5	38	9.2406425
ME13	Treino	SAG	89	90	90	90	90	90	0	90	0.3142829
ME13	Teste	Rprop+/Q	6	13	24	30	34	36	2	38	8.1248624
ME13	Treino	Rprop+/Q	89	89	90	90	90	90	0	90	0.5412854
ME13	Teste	Rprop-/Q	7	16	22	32	32	36	2	38	7.0880871
ME13	Treino	Rprop-/Q	89	89	90	90	90	90	0	90	0.3354393
ME13	Teste	SAG/Q	4	8	18	30	34	36	2	38	8.5255056
ME13	Treino	SAG/Q	89	90	90	90	90	90	0	90	0.3891255
ME14	Teste	Rprop+	16	25	48	61	66	69	4	73	14.100414
ME14	Treino	Rprop+	104	105	105	105	105	105	0	105	0.4282805
ME14	Teste	Rprop-	16	29	51	65	69	71	2	73	12.181834
ME14	Treino	Rprop-	103	105	105	105	105	105	0	105	0.8871235
ME14	Teste	SAG	17	27	42	54	64	66	7	73	16.696762
ME14	Treino	SAG	105	105	105	105	105	105	0	105	0.1549434
ME14	Teste	Rprop+/Q	16	30	46	57	64	68	5	73	14.168515
ME14	Treino	Rprop+/Q	103	105	105	105	105	105	0	105	0.5245413
ME14	Teste	Rprop-/Q	10	20	40	54	61	63	10	73	18.156408
ME14	Treino	Rprop-/Q	105	105	105	105	105	105	0	105	0.1895439
ME14	Teste	SAG/Q	11	28	51	58	62	67	6	73	15.571231
ME14	Treino	SAG/Q	103	105	105	105	105	105	0	105	0.8149658
ME15	Teste	Rprop+	9	17	25	37	42	45	4	49	10.687688
ME15	Treino	Rprop+	116	117	117	117	117	117	0	117	0.4566138
ME15	Teste	Rprop-	7	15	27	38	45	48	1	49	9.8121507
ME15	Treino	Rprop-	114	117	117	117	117	117	0	117	1.0301067
ME15	Teste	SAG	3	10	20	29	35	44	5	49	13.915338
ME15	Treino	SAG	117	117	117	117	117	117	0	117	0.3601689
ME15	Teste	Rprop+/Q	9	12	25	35	42	44	5	49	11.820136
ME15	Treino	Rprop+/Q	114	117	117	117	117	117	0	117	0.9315525
ME15	Teste	Rprop-/Q	8	12	25	36	42	43	6	49	11.680158
ME15	Treino	Rprop-/Q	117	117	117	117	117	117	0	117	0.3646471
ME15	Teste	SAG/Q	8	14	24	36	41	45	4	49	11.121876
ME15	Treino	SAG/Q	116	117	117	117	117	117	0	117	0.3806842
ME13	Teste	RProp Avg	5	9	25	33	35	35	3	38	7.7155175
ME13	Treino	RProp Avg	89	90	90	90	90	90	0	90	0.6361658
ME14	Teste	RProp Avg	15	26	49	62	68	69	4	73	12.981705

# ANEXOS- Resultados Experimentais

Modelo	Set	Algorithm	#Amostras								Soma
			Erro<5%	Erro<10%	Erro<20%	Erro<30%	Erro<40%	Erro<50%	Erro>=50%	Total	Erros
ME14	Treino	RProp Avg	105	105	105	105	105	105	0	105	0.3944622
ME15	Teste	RProp Avg	16	22	34	37	44	49	0	49	7.9978716
ME15	Treino	RProp Avg	117	117	117	117	117	117	0	117	0.4325887
ME13T14	Teste	RProp Avg	29	60	105	139	159	168	10	178	36.305034
ME13T14	Treino	RProp Avg	126	127	128	128	128	128	0	128	0.6535387
ME14T15	Teste	RProp Avg	35	62	118	145	155	158	8	166	28.518832
ME14T15	Treino	RProp Avg	178	178	178	178	178	178	0	178	0.4730196
MEGlobal	Teste	RProp Avg	29	52	89	112	125	133	9	142	27.094269
MEGlobal	Treino	RProp Avg	308	318	325	327	328	328	2	330	5.8188599
ME14T15	Teste	Rprop+	26	53	97	128	145	155	11	166	35.78951
ME14T15	Treino	Rprop+	177	178	178	178	178	178	0	178	0.8111901
ME14T15	Teste	Rprop-	32	56	96	126	140	150	16	166	35.760309
ME14T15	Treino	Rprop-	177	178	178	178	178	178	0	178	0.5661584
ME14T15	Teste	SAG	27	55	105	128	150	157	9	166	34.572164
ME14T15	Treino	SAG	176	178	178	178	178	178	0	178	0.6130349
ME14T15	Teste	Rprop+/Q	25	51	102	130	142	154	12	166	35.836768
ME14T15	Treino	Rprop+/Q	176	178	178	178	178	178	0	178	1.0468749
ME14T15	Teste	Rprop-/Q	34	61	101	134	143	154	12	166	32.911695
ME14T15	Treino	Rprop-/Q	178	178	178	178	178	178	0	178	0.7251461
ME14T15	Teste	SAG/Q	28	55	109	131	150	159	7	166	31.739276
ME14T15	Treino	SAG/Q	176	178	178	178	178	178	0	178	0.8479455
MEGlobal	Teste	Rprop+	30	54	86	111	122	129	13	142	29.246822
MEGlobal	Treino	Rprop+	309	319	325	327	328	328	2	330	5.1860612
MEGlobal	Teste	Rprop-	21	46	85	108	120	130	12	142	28.971515
MEGlobal	Treino	Rprop-	308	319	325	327	328	328	2	330	5.6241649
MEGlobal	Teste	SAG	20	42	80	103	119	127	15	142	35.139044
MEGlobal	Treino	SAG	309	319	325	327	328	328	2	330	5.4042214
MEGlobal	Teste	Rprop+/Q	16	41	70	99	113	124	18	142	36.670407
MEGlobal	Treino	Rprop+/Q	313	321	328	330	330	330	0	330	3.3224232
MEGlobal	Teste	Rprop-/Q	22	50	82	103	119	126	16	142	35.205597
MEGlobal	Treino	Rprop-/Q	311	321	328	330	330	330	0	330	3.4215226
MEGlobal	Teste	SAG/Q	21	48	82	106	125	133	9	142	30.692593
MEGlobal	Treino	SAG/Q	312	322	328	330	330	330	0	330	2.9059674
ME13	Teste	AVG6	2	8	24	28	33	36	2	38	8.0631789
ME13	Treino	AVG6	89	90	90	90	90	90	0	90	0.8991523
ME14	Teste	AVG6	12	20	45	60	65	67	6	73	15.345272
ME14	Treino	AVG6	105	105	105	105	105	105	0	105	0.7574695
ME15	Teste	AVG6	5	11	23	35	43	46	3	49	11.467485
ME15	Treino	AVG6	116	117	117	117	117	117	0	117	1.104419
ME13T14	Teste	AVG6	31	66	117	142	159	164	14	178	36.110317
ME13T14	Treino	AVG6	127	128	128	128	128	128	0	128	0.9507377
ME14T15	Teste	AVG6	30	61	113	134	146	156	10	166	31.501826
ME14T15	Treino	AVG6	176	178	178	178	178	178	0	178	1.090064
MEGlobal	Teste	AVG6	20	42	84	106	121	134	8	142	29.897965
MEGlobal	Treino	AVG6	310	319	325	327	328	328	2	330	5.8275812

Tabela A-47: Redes Neurais R - Número de amostras categorizadas por erro, modelo e algoritmo..

Modelo	Set	Algorithm	Amostras(%)						
			Erro<5%	Erro<10%	Erro<20%	Erro<30%	Erro<40%	Erro<50%	Erro>=50%
ME13T14	Teste	Rprop+	17.42%	35.39%	64.04%	78.65%	86.52%	89.89%	10.11%
ME13T14	Treino	Rprop+	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	0.00%
ME13T14	Teste	Rprop-	17.98%	30.34%	52.25%	70.79%	81.46%	87.08%	12.92%
ME13T14	Treino	Rprop-	99.22%	100.00%	100.00%	100.00%	100.00%	100.00%	0.00%

# ANEXOS- Resultados Experimentais

Modelo	Set	Algorithm	Amostras(%)						
			Erro<5%	Erro<10%	Erro<20%	Erro<30%	Erro<40%	Erro<50%	Erro>=50%
ME13T14	Teste	SAG	14.61%	34.27%	56.74%	76.97%	88.76%	91.57%	8.43%
ME13T14	Treino	SAG	95.31%	99.22%	100.00%	100.00%	100.00%	100.00%	0.00%
ME13T14	Teste	Rprop+/Q	22.47%	37.08%	63.48%	79.78%	87.64%	91.01%	8.99%
ME13T14	Treino	Rprop+/Q	99.22%	100.00%	100.00%	100.00%	100.00%	100.00%	0.00%
ME13T14	Teste	Rprop-/Q	17.42%	35.39%	60.11%	78.65%	86.52%	92.13%	7.87%
ME13T14	Treino	Rprop-/Q	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	0.00%
ME13T14	Teste	SAG/Q	21.35%	42.13%	63.48%	74.72%	86.52%	93.82%	6.18%
ME13T14	Treino	SAG/Q	99.22%	99.22%	100.00%	100.00%	100.00%	100.00%	0.00%
ME13	Teste	Rprop+	15.79%	34.21%	63.16%	84.21%	86.84%	86.84%	13.16%
ME13	Treino	Rprop+	96.67%	100.00%	100.00%	100.00%	100.00%	100.00%	0.00%
ME13	Teste	Rprop-	18.42%	26.32%	52.63%	76.32%	84.21%	92.11%	7.89%
ME13	Treino	Rprop-	98.89%	100.00%	100.00%	100.00%	100.00%	100.00%	0.00%
ME13	Teste	SAG	13.16%	26.32%	55.26%	73.68%	81.58%	86.84%	13.16%
ME13	Treino	SAG	98.89%	100.00%	100.00%	100.00%	100.00%	100.00%	0.00%
ME13	Teste	Rprop+/Q	15.79%	34.21%	63.16%	78.95%	89.47%	94.74%	5.26%
ME13	Treino	Rprop+/Q	98.89%	98.89%	100.00%	100.00%	100.00%	100.00%	0.00%
ME13	Teste	Rprop-/Q	18.42%	42.11%	57.89%	84.21%	84.21%	94.74%	5.26%
ME13	Treino	Rprop-/Q	98.89%	98.89%	100.00%	100.00%	100.00%	100.00%	0.00%
ME13	Teste	SAG/Q	10.53%	21.05%	47.37%	78.95%	89.47%	94.74%	5.26%
ME13	Treino	SAG/Q	98.89%	100.00%	100.00%	100.00%	100.00%	100.00%	0.00%
ME14	Teste	Rprop+	21.92%	34.25%	65.75%	83.56%	90.41%	94.52%	5.48%
ME14	Treino	Rprop+	99.05%	100.00%	100.00%	100.00%	100.00%	100.00%	0.00%
ME14	Teste	Rprop-	21.92%	39.73%	69.86%	89.04%	94.52%	97.26%	2.74%
ME14	Treino	Rprop-	98.10%	100.00%	100.00%	100.00%	100.00%	100.00%	0.00%
ME14	Teste	SAG	23.29%	36.99%	57.53%	73.97%	87.67%	90.41%	9.59%
ME14	Treino	SAG	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	0.00%
ME14	Teste	Rprop+/Q	21.92%	41.10%	63.01%	78.08%	87.67%	93.15%	6.85%
ME14	Treino	Rprop+/Q	98.10%	100.00%	100.00%	100.00%	100.00%	100.00%	0.00%
ME14	Teste	Rprop-/Q	13.70%	27.40%	54.79%	73.97%	83.56%	86.30%	13.70%
ME14	Treino	Rprop-/Q	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	0.00%
ME14	Teste	SAG/Q	15.07%	38.36%	69.86%	79.45%	84.93%	91.78%	8.22%
ME14	Treino	SAG/Q	98.10%	100.00%	100.00%	100.00%	100.00%	100.00%	0.00%
ME15	Teste	Rprop+	18.37%	34.69%	51.02%	75.51%	85.71%	91.84%	8.16%
ME15	Treino	Rprop+	99.15%	100.00%	100.00%	100.00%	100.00%	100.00%	0.00%
ME15	Teste	Rprop-	14.29%	30.61%	55.10%	77.55%	91.84%	97.96%	2.04%
ME15	Treino	Rprop-	97.44%	100.00%	100.00%	100.00%	100.00%	100.00%	0.00%
ME15	Teste	SAG	6.12%	20.41%	40.82%	59.18%	71.43%	89.80%	10.20%
ME15	Treino	SAG	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	0.00%
ME15	Teste	Rprop+/Q	18.37%	24.49%	51.02%	71.43%	85.71%	89.80%	10.20%
ME15	Treino	Rprop+/Q	97.44%	100.00%	100.00%	100.00%	100.00%	100.00%	0.00%
ME15	Teste	Rprop-/Q	16.33%	24.49%	51.02%	73.47%	85.71%	87.76%	12.24%
ME15	Treino	Rprop-/Q	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	0.00%
ME15	Teste	SAG/Q	16.33%	28.57%	48.98%	73.47%	83.67%	91.84%	8.16%
ME15	Treino	SAG/Q	99.15%	100.00%	100.00%	100.00%	100.00%	100.00%	0.00%
ME13	Teste	RProp Avg	13.16%	23.68%	65.79%	86.84%	92.11%	92.11%	7.89%
ME13	Treino	RProp Avg	98.89%	100.00%	100.00%	100.00%	100.00%	100.00%	0.00%
ME14	Teste	RProp Avg	20.55%	35.62%	67.12%	84.93%	93.15%	94.52%	5.48%
ME14	Treino	RProp Avg	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	0.00%
ME15	Teste	RProp Avg	32.65%	44.90%	69.39%	75.51%	89.80%	100.00%	0.00%
ME15	Treino	RProp Avg	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	0.00%
ME13T14	Teste	RProp Avg	16.29%	33.71%	58.99%	78.09%	89.33%	94.38%	5.62%
ME13T14	Treino	RProp Avg	98.44%	99.22%	100.00%	100.00%	100.00%	100.00%	0.00%
ME14T15	Teste	RProp Avg	21.08%	37.35%	71.08%	87.35%	93.37%	95.18%	4.82%
ME14T15	Treino	RProp Avg	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	0.00%
MEGlobal	Teste	RProp Avg	20.42%	36.62%	62.68%	78.87%	88.03%	93.66%	6.34%

# ANEXOS- Resultados Experimentais

Modelo	Set	Algorithm	Amostras(%)						
			Erro<5%	Erro<10%	Erro<20%	Erro<30%	Erro<40%	Erro<50%	Erro>=50%
MEGlobal	Treino	RProp Avg	93.33%	96.36%	98.48%	99.09%	99.39%	99.39%	0.61%
ME14T15	Teste	Rprop+	15.66%	31.93%	58.43%	77.11%	87.35%	93.37%	6.63%
ME14T15	Treino	Rprop+	99.44%	100.00%	100.00%	100.00%	100.00%	100.00%	0.00%
ME14T15	Teste	Rprop-	19.28%	33.73%	57.83%	75.90%	84.34%	90.36%	9.64%
ME14T15	Treino	Rprop-	99.44%	100.00%	100.00%	100.00%	100.00%	100.00%	0.00%
ME14T15	Teste	SAG	16.27%	33.13%	63.25%	77.11%	90.36%	94.58%	5.42%
ME14T15	Treino	SAG	98.88%	100.00%	100.00%	100.00%	100.00%	100.00%	0.00%
ME14T15	Teste	Rprop+/Q	15.06%	30.72%	61.45%	78.31%	85.54%	92.77%	7.23%
ME14T15	Treino	Rprop+/Q	98.88%	100.00%	100.00%	100.00%	100.00%	100.00%	0.00%
ME14T15	Teste	Rprop-/Q	20.48%	36.75%	60.84%	80.72%	86.14%	92.77%	7.23%
ME14T15	Treino	Rprop-/Q	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	0.00%
ME14T15	Teste	SAG/Q	16.87%	33.13%	65.66%	78.92%	90.36%	95.78%	4.22%
ME14T15	Treino	SAG/Q	98.88%	100.00%	100.00%	100.00%	100.00%	100.00%	0.00%
MEGlobal	Teste	Rprop+	21.13%	38.03%	60.56%	78.17%	85.92%	90.85%	9.15%
MEGlobal	Treino	Rprop+	93.64%	96.67%	98.48%	99.09%	99.39%	99.39%	0.61%
MEGlobal	Teste	Rprop-	14.79%	32.39%	59.86%	76.06%	84.51%	91.55%	8.45%
MEGlobal	Treino	Rprop-	93.33%	96.67%	98.48%	99.09%	99.39%	99.39%	0.61%
MEGlobal	Teste	SAG	14.08%	29.58%	56.34%	72.54%	83.80%	89.44%	10.56%
MEGlobal	Treino	SAG	93.64%	96.67%	98.48%	99.09%	99.39%	99.39%	0.61%
MEGlobal	Teste	Rprop+/Q	11.27%	28.87%	49.30%	69.72%	79.58%	87.32%	12.68%
MEGlobal	Treino	Rprop+/Q	94.85%	97.27%	99.39%	100.00%	100.00%	100.00%	0.00%
MEGlobal	Teste	Rprop-/Q	15.49%	35.21%	57.75%	72.54%	83.80%	88.73%	11.27%
MEGlobal	Treino	Rprop-/Q	94.24%	97.27%	99.39%	100.00%	100.00%	100.00%	0.00%
MEGlobal	Teste	SAG/Q	14.79%	33.80%	57.75%	74.65%	88.03%	93.66%	6.34%
MEGlobal	Treino	SAG/Q	94.55%	97.58%	99.39%	100.00%	100.00%	100.00%	0.00%
ME13	Teste	AVG6	5.26%	21.05%	63.16%	73.68%	86.84%	94.74%	5.26%
ME13	Treino	AVG6	98.89%	100.00%	100.00%	100.00%	100.00%	100.00%	0.00%
ME14	Teste	AVG6	16.44%	27.40%	61.64%	82.19%	89.04%	91.78%	8.22%
ME14	Treino	AVG6	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	0.00%
ME15	Teste	AVG6	10.20%	22.45%	46.94%	71.43%	87.76%	93.88%	6.12%
ME15	Treino	AVG6	99.15%	100.00%	100.00%	100.00%	100.00%	100.00%	0.00%
ME13T14	Teste	AVG6	17.42%	37.08%	65.73%	79.78%	89.33%	92.13%	7.87%
ME13T14	Treino	AVG6	99.22%	100.00%	100.00%	100.00%	100.00%	100.00%	0.00%
ME14T15	Teste	AVG6	18.07%	36.75%	68.07%	80.72%	87.95%	93.98%	6.02%
ME14T15	Treino	AVG6	98.88%	100.00%	100.00%	100.00%	100.00%	100.00%	0.00%
MEGlobal	Teste	AVG6	14.08%	29.58%	59.15%	74.65%	85.21%	94.37%	5.63%
MEGlobal	Treino	AVG6	93.94%	96.67%	98.48%	99.09%	99.39%	99.39%	0.61%

Tabela A-48: Redes Neurais R - Percentagem de amostras categorizadas por erro, modelo e algoritmo..

Modelo	Set	Algorithm	Erro	Real			Previsão		
			Médio	Min	Max	Amplitude	Min	Max	Amplitude
ME13T14	Teste	Rprop+	0.2120	0.5236	1.9631	1.4395	0.5366	2.0034	1.4669
ME13T14	Treino	Rprop+	0.0026	0.5722	1.8925	1.3203	0.5731	1.8915	1.3183
ME13T14	Teste	Rprop-	0.2485	0.5236	1.9631	1.4395	0.3118	2.5823	2.2705
ME13T14	Treino	Rprop-	0.0050	0.5722	1.8925	1.3203	0.5737	1.8930	1.3192
ME13T14	Teste	SAG	0.2183	0.5236	1.9631	1.4395	0.6645	2.6411	1.9767
ME13T14	Treino	SAG	0.0128	0.5722	1.8925	1.3203	0.5678	1.8976	1.3298
ME13T14	Teste	Rprop+/Q	0.2039	0.5236	1.9631	1.4395	0.5667	1.9300	1.3633
ME13T14	Treino	Rprop+/Q	0.0036	0.5722	1.8925	1.3203	0.5731	1.8900	1.3169
ME13T14	Teste	Rprop-/Q	0.2126	0.5236	1.9631	1.4395	0.5134	1.8265	1.3131
ME13T14	Treino	Rprop-/Q	0.0062	0.5722	1.8925	1.3203	0.5703	1.8926	1.3223
ME13T14	Teste	SAG/Q	0.2020	0.5236	1.9631	1.4395	0.6135	1.8335	1.2200

# ANEXOS- Resultados Experimentais

			Erro	Real			Previsão		
Modelo	Set	Algorithm	Médio	Min	Max	Amplitude	Min	Max	Amplitude
ME13T14	Treino	SAG/Q	0.0040	0.5722	1.8925	1.3203	0.5730	1.8907	1.3177
ME13	Teste	Rprop+	0.2382	0.7730	1.8925	1.1196	0.7935	2.1751	1.3816
ME13	Treino	Rprop+	0.0101	0.5722	1.8846	1.3124	0.5764	1.8890	1.3126
ME13	Teste	Rprop-	0.2152	0.7730	1.8925	1.1196	0.6442	2.0640	1.4197
ME13	Treino	Rprop-	0.0049	0.5722	1.8846	1.3124	0.5739	1.8839	1.3100
ME13	Teste	SAG	0.2432	0.7730	1.8925	1.1196	0.5243	2.1100	1.5857
ME13	Treino	SAG	0.0035	0.5722	1.8846	1.3124	0.5722	1.8846	1.3124
ME13	Teste	Rprop+/Q	0.2138	0.7730	1.8925	1.1196	0.4519	1.7376	1.2857
ME13	Treino	Rprop+/Q	0.0060	0.5722	1.8846	1.3124	0.5711	1.8810	1.3099
ME13	Teste	Rprop-/Q	0.1865	0.7730	1.8925	1.1196	0.7396	1.4367	0.6972
ME13	Treino	Rprop-/Q	0.0037	0.5722	1.8846	1.3124	0.5965	1.8779	1.2814
ME13	Teste	SAG/Q	0.2244	0.7730	1.8925	1.1196	0.6995	1.5094	0.8100
ME13	Treino	SAG/Q	0.0043	0.5722	1.8846	1.3124	0.5747	1.8851	1.3104
ME14	Teste	Rprop+	0.1932	0.5624	1.7487	1.1863	0.6045	1.9195	1.3150
ME14	Treino	Rprop+	0.0041	0.5236	1.9631	1.4395	0.5252	1.9552	1.4300
ME14	Teste	Rprop-	0.1669	0.5624	1.7487	1.1863	0.7638	1.4368	0.6730
ME14	Treino	Rprop-	0.0084	0.5236	1.9631	1.4395	0.5235	1.9665	1.4429
ME14	Teste	SAG	0.2287	0.5624	1.7487	1.1863	0.2151	2.1711	1.9560
ME14	Treino	SAG	0.0015	0.5236	1.9631	1.4395	0.5233	1.9618	1.4385
ME14	Teste	Rprop+/Q	0.1941	0.5624	1.7487	1.1863	0.4574	1.7439	1.2864
ME14	Treino	Rprop+/Q	0.0050	0.5236	1.9631	1.4395	0.5225	1.9652	1.4427
ME14	Teste	Rprop-/Q	0.2487	0.5624	1.7487	1.1863	0.5182	2.1061	1.5879
ME14	Treino	Rprop-/Q	0.0018	0.5236	1.9631	1.4395	0.5259	1.9638	1.4379
ME14	Teste	SAG/Q	0.2133	0.5624	1.7487	1.1863	0.1884	1.8036	1.6152
ME14	Treino	SAG/Q	0.0078	0.5236	1.9631	1.4395	0.5161	1.9290	1.4129
ME15	Teste	Rprop+	0.2181	0.6551	1.8222	1.1671	0.6445	1.6232	0.9787
ME15	Treino	Rprop+	0.0039	0.6006	1.9178	1.3172	0.6049	1.9152	1.3103
ME15	Teste	Rprop-	0.2002	0.6551	1.8222	1.1671	0.7573	1.9489	1.1915
ME15	Treino	Rprop-	0.0088	0.6006	1.9178	1.3172	0.5943	1.9168	1.3226
ME15	Teste	SAG	0.2840	0.6551	1.8222	1.1671	0.3623	2.3398	1.9775
ME15	Treino	SAG	0.0031	0.6006	1.9178	1.3172	0.6001	1.9145	1.3144
ME15	Teste	Rprop+/Q	0.2412	0.6551	1.8222	1.1671	0.7937	1.8321	1.0384
ME15	Treino	Rprop+/Q	0.0080	0.6006	1.9178	1.3172	0.5972	1.9040	1.3068
ME15	Teste	Rprop-/Q	0.2384	0.6551	1.8222	1.1671	0.9033	2.8707	1.9674
ME15	Treino	Rprop-/Q	0.0031	0.6006	1.9178	1.3172	0.5996	1.9251	1.3255
ME15	Teste	SAG/Q	0.2270	0.6551	1.8222	1.1671	0.6954	1.9124	1.2170
ME15	Treino	SAG/Q	0.0033	0.6006	1.9178	1.3172	0.6001	1.9219	1.3218
ME13	Teste	RProp Avg	0.2030	0.7730	1.8925	1.1196	0.7977	1.4953	0.6977
ME13	Treino	RProp Avg	0.0071	0.5722	1.8846	1.3124	0.5692	1.8900	1.3209
ME14	Teste	RProp Avg	0.1778	0.5624	1.7487	1.1863	0.7239	1.5514	0.8276
ME14	Treino	RProp Avg	0.0038	0.5236	1.9631	1.4395	0.5229	1.9618	1.4388
ME15	Teste	RProp Avg	0.1632	0.6551	1.8222	1.1671	0.7019	1.3827	0.6808
ME15	Treino	RProp Avg	0.0037	0.6006	1.9178	1.3172	0.6042	1.9227	1.3185
ME13T14	Teste	RProp Avg	0.2040	0.5236	1.9631	1.4395	0.6662	1.8841	1.2179
ME13T14	Treino	RProp Avg	0.0051	0.5722	1.8925	1.3203	0.5731	1.8933	1.3202
ME14T15	Teste	RProp Avg	0.1718	0.6006	1.9178	1.3172	0.7785	1.6872	0.9086
ME14T15	Treino	RProp Avg	0.0027	0.5236	1.9631	1.4395	0.5240	1.9641	1.4401
MEGlobal	Teste	RProp Avg	0.1908	0.5236	1.8550	1.3314	0.4963	1.7787	1.2824
MEGlobal	Treino	RProp Avg	0.0176	0.5624	1.9631	1.4007	0.5694	1.9642	1.3948
ME14T15	Teste	Rprop+	0.2156	0.6006	1.9178	1.3172	0.6362	2.0194	1.3831
ME14T15	Treino	Rprop+	0.0046	0.5236	1.9631	1.4395	0.5221	1.9618	1.4397
ME14T15	Teste	Rprop-	0.2154	0.6006	1.9178	1.3172	0.1448	2.1021	1.9573

## ANEXOS- Resultados Experimentais

			Erro	Real			Previsão		
Modelo	Set	Algorithm	Médio	Min	Max	Amplitude	Min	Max	Amplitude
ME14T15	Treino	Rprop-	0.0032	0.5236	1.9631	1.4395	0.5256	1.9633	1.4377
ME14T15	Teste	SAG	0.2083	0.6006	1.9178	1.3172	0.6099	2.5650	1.9551
ME14T15	Treino	SAG	0.0034	0.5236	1.9631	1.4395	0.5269	1.9641	1.4372
ME14T15	Teste	Rprop+/Q	0.2159	0.6006	1.9178	1.3172	0.3684	1.8608	1.4924
ME14T15	Treino	Rprop+/Q	0.0059	0.5236	1.9631	1.4395	0.5211	1.9569	1.4358
ME14T15	Teste	Rprop-/Q	0.1983	0.6006	1.9178	1.3172	0.6346	1.9049	1.2703
ME14T15	Treino	Rprop-/Q	0.0041	0.5236	1.9631	1.4395	0.5258	1.9638	1.4379
ME14T15	Teste	SAG/Q	0.1912	0.6006	1.9178	1.3172	0.5694	1.8359	1.2666
ME14T15	Treino	SAG/Q	0.0048	0.5236	1.9631	1.4395	0.5263	1.9613	1.4350
MEGlobal	Teste	Rprop+	0.2060	0.5236	1.8550	1.3314	0.4685	1.6223	1.1538
MEGlobal	Treino	Rprop+	0.0157	0.5624	1.9631	1.4007	0.5644	1.9771	1.4128
MEGlobal	Teste	Rprop-	0.2040	0.5236	1.8550	1.3314	0.3912	1.9126	1.5214
MEGlobal	Treino	Rprop-	0.0170	0.5624	1.9631	1.4007	0.5612	1.9663	1.4051
MEGlobal	Teste	SAG	0.2475	0.5236	1.8550	1.3314	0.1682	2.8835	2.7154
MEGlobal	Treino	SAG	0.0164	0.5624	1.9631	1.4007	0.5632	1.9614	1.3982
MEGlobal	Teste	Rprop+/Q	0.2582	0.5722	1.9631	1.3909	0.4196	1.7770	1.3573
MEGlobal	Treino	Rprop+/Q	0.0101	0.5236	1.9178	1.3942	0.5260	1.9134	1.3874
MEGlobal	Teste	Rprop-/Q	0.2479	0.5722	1.9631	1.3909	0.5951	2.3513	1.7561
MEGlobal	Treino	Rprop-/Q	0.0104	0.5236	1.9178	1.3942	0.5249	1.9177	1.3927
MEGlobal	Teste	SAG/Q	0.2161	0.5722	1.9631	1.3909	-0.0016	1.6809	1.6825
MEGlobal	Treino	SAG/Q	0.0088	0.5236	1.9178	1.3942	0.5253	1.9180	1.3927
ME13	Teste	AVG6	0.2122	0.7730	1.8925	1.1196	0.7482	1.5255	0.7773
ME13	Treino	AVG6	0.0100	0.5722	1.8846	1.3124	0.5716	1.8840	1.3124
ME14	Teste	AVG6	0.2102	0.5624	1.7487	1.1863	0.3899	1.6393	1.2494
ME14	Treino	AVG6	0.0072	0.5236	1.9631	1.4395	0.5277	1.9488	1.4210
ME15	Teste	AVG6	0.2340	0.6551	1.8222	1.1671	0.7587	1.8504	1.0917
ME15	Treino	AVG6	0.0094	0.6006	1.9178	1.3172	0.5948	1.9170	1.3222
ME13T14	Teste	AVG6	0.2029	0.5236	1.9631	1.4395	0.7023	1.9949	1.2926
ME13T14	Treino	AVG6	0.0074	0.5722	1.8925	1.3203	0.5724	1.8931	1.3207
ME14T15	Teste	AVG6	0.1898	0.6006	1.9178	1.3172	0.7164	1.8029	1.0864
ME14T15	Treino	AVG6	0.0061	0.5236	1.9631	1.4395	0.5249	1.9556	1.4307
MEGlobal	Teste	AVG6	0.2105	0.5236	1.8550	1.3314	0.2646	1.7794	1.5148
MEGlobal	Treino	AVG6	0.0177	0.5624	1.9631	1.4007	0.5599	1.9391	1.3793

*Tabela A-49:Redes Neurais R - Erros, amplitudes por modelo e algoritmo*

### A.3.3 Árvores de Decisão R

#### *Modelo Estratégico 2013*

x_0	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_10	Set	y	y'	Erro Abs(%)
0	5	0	0	0	0	0	0	0	0	0	T	1.1	0.7	36.364%
-5	7	0	6	5	6	-7	8	0	0	7	T	1	0.9	10.000%
-5	0	9	0	0	0	0	5	0	0	0	T	0.85	0.8	5.882%
0	0	0	0	0	0	0	0	0	5	8	T	0.95	1.15	21.053%
7	5	3	0	0	8	-8	0	5	0	0	T	0.85	1.1	29.412%
-2	-1	7	0	1	0	-4	3	3	1	7	T	1	1.05	5.000%
1	3	0	7	0	1	0	0	2	0	0	T	1.15	1.2	4.348%
0	0	0	2	1	0	3	2	2	0	3	T	1	1.3	30.000%

# ANEXOS- Resultados Experimentais

x_0	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_10	Set	y	y'	Erro Abs(%)
0	0	2	0	1	1	5	2	5	7	9	T	0.95	1.15	21.053%
2	5	0	3	5	-3	-3	0	2	0	2	T	1.1	1	9.091%
0	3	0	2	0	-4	-3	4	3	0	7	T	1.6	0.9	43.750%
0	9	0	6	0	-4	-7	7	9	0	0	T	1.2	1.2	0.000%
-1	-2	2	5	7	-5	-4	5	6	5	7	T	1.2	1.2	0.000%
-5	7	5	7	5	5	-4	0	0	0	2	T	1.25	0.9	28.000%
-5	0	4	0	0	0	0	8	0	5	8	T	1.4	1.15	17.857%
0	4	0	5	0	0	-2	0	0	0	5	T	0.95	0.9	5.263%
1	4	2	0	0	8	2	8	8	0	8	T	0.8	1.05	31.250%
-4	-2	2	4	2	-3	-5	5	4	0	4	T	1.1	1.2	9.091%
-5	-5	9	0	0	2	-5	0	6	8	9	T	0.95	1.15	21.053%
-9	9	5	5	0	0	0	0	0	0	6	T	1.9	0.8	57.895%
-7	-5	0	3	0	-4	-3	0	4	3	0	T	1.1	0.9	18.182%
2	2	0	3	0	3	-6	5	1	1	1	T	1.2	1.3	8.333%
0	5	0	2	0	0	0	5	0	5	3	T	1	1.05	5.000%
-5	0	0	5	7	-5	-5	0	5	0	0	T	0.9	1	11.111%
1	2	0	2	2	-2	2	2	3	0	0	T	1.05	1.3	23.810%
-6	-9	0	0	0	0	0	0	0	0	0	T	1.2	1.25	4.167%
5	5	0	5	0	-5	-5	5	5	5	9	T	1.1	0.65	40.909%
3	4	0	4	3	5	-4	3	5	5	3	T	1.1	1.9	72.727%
6	5	0	0	0	7	0	7	0	6	0	T	0.8	1.15	43.750%
-4	0	1	0	0	-5	-1	3	3	0	3	T	1	1	0.000%
0	0	0	7	0	0	-6	7	7	0	0	T	1.05	1.2	14.286%
-4	7	0	7	0	4	0	0	3	3	4	T	1.3	1.2	7.692%
0	3	0	1	0	0	-1	0	2	0	0	T	0.95	0.7	26.316%
0	4	0	0	0	2	0	0	0	0	0	T	1.4	0.7	50.000%
0	6	0	6	6	-7	-4	3	5	1	6	T	1.25	1	20.000%
0	0	7	0	0	-6	-6	5	3	0	7	T	1.1	1.25	13.636%
4	8	0	5	9	-4	-5	4	5	0	5	T	0.75	0.65	13.333%
-1	-1	0	0	0	-7	0	1	7	0	4	T	1	0.9	10.000%
3	7	0	5	0	7	-6	7	7	4	2	P	1.05	1.05	0.000%
0	0	5	0	0	2	0	2	0	0	0	P	0.85	0.8	5.882%
-3	0	0	5	8	-6	-3	0	0	0	6	P	1.25	1.25	0.000%
0	6	0	6	4	0	0	0	0	0	0	P	0.9	0.9	0.000%
5	9	0	6	6	0	0	4	5	4	7	P	1.15	1.15	0.000%
-3	3	3	1	3	3	3	3	3	2	0	P	0.65	0.7	7.692%
-6	-5	0	6	0	0	0	7	0	6	5	P	1	1	0.000%
7	7	0	6	0	0	-6	0	0	0	6	P	0.55	0.65	18.182%
2	0	0	4	4	-4	-1	0	0	1	3	P	0.95	1	5.263%
0	6	0	5	0	-6	-3	0	6	4	4	P	1	1	0.000%
2	4	0	3	0	0	0	3	4	0	0	P	1	1	0.000%
0	2	0	0	0	0	-3	0	0	0	0	P	1.15	1.1	4.348%
-7	5	8	1	5	5	-4	0	0	2	2	P	1.05	1.1	4.762%
-4	-3	2	3	9	-3	-6	7	3	3	6	P	1.15	1.2	4.348%
-1	-1	2	0	0	-1	-1	0	0	2	2	P	0.75	0.75	0.000%
-4	-5	4	4	0	4	-4	0	4	0	0	P	0.95	0.95	0.000%
6	7	0	5	4	5	-6	6	2	6	3	P	1.15	1.2	4.348%
-8	7	0	0	0	5	0	2	7	0	0	P	0.7	0.7	0.000%
-2	-1	6	4	2	-5	-7	0	3	3	4	P	1.05	1	4.762%
0	5	4	0	6	-9	-9	9	0	0	0	P	0.75	0.8	6.667%
0	0	0	0	5	0	-3	0	2	0	0	P	0.7	0.65	7.143%
0	2	0	2	0	3	3	0	2	0	0	P	1.3	1.3	0.000%
-1	6	0	2	9	-9	-3	5	6	3	2	P	1.2	1.2	0.000%



# ANEXOS- Resultados Experimentais

x_0	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_10	Set	y	y'	Erro Abs(%)
0	5	0	4	3	-5	0	5	0	0	0	P	0.95	0.9	5.263%
3	6	1	3	3	6	0	7	3	4	4	P	1.85	1.9	2.703%
-6	-1	9	2	0	-6	-6	0	0	8	9	P	1.05	1.05	0.000%
0	5	0	3	0	5	-4	3	4	0	5	P	1.2	1.2	0.000%
0	4	0	4	0	-5	0	5	4	0	5	P	1.2	1.2	0.000%
-2	-3	6	0	0	0	-7	2	0	0	5	P	1.05	1.05	0.000%
2	6	0	0	0	-8	0	8	6	0	0	P	0.9	0.8	11.111%
0	7	0	0	2	-5	-2	0	0	7	0	P	1.35	1.35	0.000%
6	2	9	0	0	0	-1	6	3	0	2	P	1	1	0.000%
-3	-3	0	5	4	-6	4	8	4	1	6	P	1.25	1.2	4.000%
-1	0	5	0	9	0	2	1	0	0	0	P	1.05	1.05	0.000%
4	7	0	4	0	-8	-4	0	0	0	4	P	1.9	1.7	10.526%
-9	0	9	5	5	-5	0	0	0	5	9	P	0.8	0.8	0.000%
-8	-6	1	8	5	0	0	7	0	8	7	P	0.75	0.8	6.667%
-5	0	1	0	0	0	2	0	0	0	0	P	0.75	0.8	6.667%
6	0	5	0	0	-5	-5	6	0	0	5	P	1.35	1.25	7.407%
1	3	0	0	0	-4	-5	4	4	0	5	P	1	1.05	5.000%
2	3	0	0	4	-4	0	0	3	0	2	P	0.95	1	5.263%
0	0	0	0	0	0	0	2	3	0	4	P	1	1	0.000%
0	7	1	3	5	-5	7	3	4	3	1	P	1	1	0.000%
-4	6	0	6	0	-6	-6	6	5	6	6	P	1.05	1.1	4.762%
1	0	0	1	0	0	-1	1	0	1	1	P	1.15	1.1	4.348%
-5	0	0	0	0	0	-5	6	0	0	5	P	1	1.05	5.000%
-2	-1	0	0	2	3	0	0	0	0	4	P	0.95	0.9	5.263%
0	0	0	4	0	-3	-6	0	5	7	0	P	1.1	1.1	0.000%
4	7	0	0	0	0	0	4	0	0	0	P	0.75	0.7	6.667%
0	5	0	4	0	-4	-4	4	4	4	4	P	0.9	0.9	0.000%
-1	0	8	2	0	-6	4	0	5	6	1	P	0.9	0.9	0.000%
1	4	0	7	0	6	-8	2	8	0	0	P	1.05	1.1	4.762%
1	3	0	3	0	-3	-6	0	5	5	5	P	1.2	1.2	0.000%
2	4	0	7	0	-5	-3	0	2	0	4	P	1	1	0.000%
0	0	5	3	0	0	-2	0	3	4	0	P	1.2	1.2	0.000%
5	5	0	4	3	-4	-4	5	2	0	5	P	0.75	0.65	13.333%
-1	0	0	1	9	-9	-7	9	7	0	5	P	1.15	1.25	8.696%
4	7	0	0	0	4	4	0	0	0	2	P	0.85	0.85	0.000%
-2	3	0	0	6	9	-9	7	5	0	0	P	1.05	1.1	4.762%
-4	4	0	4	3	2	-3	0	0	3	3	P	0.9	0.9	0.000%
0	0	0	5	0	-5	-6	5	5	5	0	P	1.2	1.2	0.000%
3	7	0	9	0	2	-8	6	3	3	4	P	1.2	1.2	0.000%
0	-1	0	1	0	-1	-1	1	1	1	1	P	0.9	0.9	0.000%
0	2	6	6	5	-2	0	0	4	4	5	P	1.15	1.2	4.348%
7	6	0	4	0	8	3	5	8	5	0	P	1.3	1.3	0.000%
-8	5	0	0	0	3	-4	6	0	0	8	P	0.85	0.85	0.000%
3	6	2	4	5	-8	-8	0	4	3	6	P	1.15	1.15	0.000%
-3	6	0	4	0	-3	-4	4	7	0	4	P	1.2	1.2	0.000%
0	3	0	4	0	0	0	0	0	0	2	P	0.8	0.8	0.000%
-3	-3	0	0	0	0	0	0	0	0	0	P	1.25	1.25	0.000%
-3	-4	2	3	3	-5	-5	5	5	1	3	P	1.3	1.3	0.000%
0	0	0	0	0	4	-1	0	0	3	0	P	1.2	1.15	4.167%
3	1	0	0	0	-4	0	5	2	0	0	P	0.9	0.95	5.556%
6	5	0	0	0	3	4	5	2	0	7	P	1.05	1.05	0.000%
-5	0	5	7	0	0	-7	3	4	4	7	P	1.2	1.2	0.000%
-8	0	0	0	0	0	0	0	0	0	0	P	1	0.95	5.000%

## ANEXOS- Resultados Experimentais

x_0	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_10	Set	y	y'	Erro Abs(%)
-7	7	0	3	0	0	-7	0	8	0	6	P	1.1	1.1	0.000%
0	0	0	0	5	0	0	0	0	0	0	P	0.6	0.65	8.333%
-5	9	0	5	0	0	-7	0	7	0	9	P	1.1	1.1	0.000%
5	6	0	6	0	6	-5	2	4	0	4	P	1.25	1.2	4.000%
1	1	0	6	0	7	0	0	0	0	0	P	1.15	1.15	0.000%
0	5	0	0	0	0	-5	3	0	0	0	P	0.7	0.7	0.000%
0	6	0	0	0	7	-9	8	0	6	9	P	1.15	1.15	0.000%
-5	5	0	4	4	5	-5	6	6	6	5	P	0.95	0.9	5.263%
0	0	0	9	0	-9	0	9	0	0	0	P	0.8	0.8	0.000%
2	5	0	4	0	2	-6	0	5	5	5	P	1.9	1.9	0.000%
7	7	0	7	0	-7	0	0	0	0	0	P	1.55	1.7	9.677%
0	0	0	0	0	1	0	0	0	0	8	P	1.1	1.05	4.545%
0	0	0	0	0	8	-9	8	9	0	0	P	1.2	1.1	8.333%
2	2	0	0	0	0	0	0	2	0	0	P	1	1.1	10.000%

Tabela A-50: Árvore de Decisão R - Resultados Modelo Estratégico ME13ADR

### Modelo Estratégico 2014

x_0	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_10	Set	y	y'	Erro Abs(%)
-6	0	0	5	0	5	0	0	6	0	7	T	1.05	1.25	19.0476%
-2	-1	7	0	1	0	-4	4	3	1	7	T	0.85	0.6	29.4118%
-5	-1	5	4	2	-6	-4	3	2	4	6	T	0.55	1.3	136.3636%
1	4	0	3	0	0	0	3	6	0	0	T	1.15	1.15	0.0000%
0	4	0	2	0	-5	-4	0	0	2	3	T	0.95	1.15	21.0526%
-5	7	5	7	5	6	-5	3	0	4	5	T	1	0.8	20.0000%
-6	6	0	0	8	0	-2	4	0	0	3	T	0.9	1.15	27.7778%
5	4	0	0	0	0	-1	6	6	0	5	T	0.85	1	17.6471%
6	0	5	0	0	-5	-6	6	0	0	5	T	0.9	0.6	33.3333%
-7	-2	6	0	0	-4	0	0	6	7	9	T	0.75	1.3	73.3333%
-7	0	8	7	7	0	0	0	0	0	3	T	1.15	1.15	0.0000%
-3	0	0	2	7	3	-5	5	4	5	6	T	1.1	1.15	4.5455%
2	4	0	5	0	5	-5	5	1	4	2	T	1.5	1.2	20.0000%
0	7	2	6	0	-7	-6	5	5	0	0	T	1.05	1.2	14.2857%
0	0	0	4	0	0	0	0	2	0	5	T	1.1	0.9	18.1818%
3	1	0	4	0	-4	-3	4	3	0	0	T	1.2	0.6	50.0000%
0	0	0	2	0	-1	-3	4	2	0	1	T	1.25	0.6	52.0000%
1	2	0	4	3	-3	-6	4	4	5	0	T	1.1	0.85	22.7273%
-6	3	8	1	6	0	-2	1	3	7	7	T	1	1.15	15.0000%
0	0	0	0	5	0	0	0	5	6	9	T	1.05	1.15	9.5238%
-6	-3	0	0	0	0	0	0	0	0	0	T	1.3	1.05	19.2308%
0	0	0	7	0	0	-6	7	6	0	0	T	1	1	0.0000%
-6	0	5	7	0	0	-7	3	4	4	7	T	1.25	0.95	24.0000%
1	3	0	7	0	6	-5	4	6	2	5	T	1.1	1.15	4.5455%
-4	0	0	4	1	-3	-4	4	2	1	4	T	1.5	1.15	23.3333%
0	0	0	5	0	-6	-7	7	5	0	9	T	1.2	1	16.6667%
5	6	0	1	0	0	4	0	0	0	0	T	1.35	1.25	7.4074%
0	5	9	0	0	5	-5	5	0	5	0	T	1	1.2	20.0000%
4	5	0	5	2	7	-7	8	3	5	7	T	1.3	1.2	7.6923%
-1	-3	0	4	0	-6	-6	0	0	4	5	T	1.55	0.9	41.9355%
-3	4	3	1	3	3	3	3	3	3	0	T	0.85	1.15	35.2941%
-2	0	0	0	3	0	-6	6	0	0	0	T	1.2	0.6	50.0000%
-2	0	0	0	0	0	-1	0	3	0	4	T	0.95	0.9	5.2632%
8	8	0	5	6	4	-5	7	4	0	0	T	1.1	1.2	9.0909%
-8	0	5	5	0	0	-4	6	7	7	8	T	1	1.3	30.0000%

# ANEXOS- Resultados Experimentais

x_0	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_10	Set	y	y'	Erro Abs(%)
-1	6	0	2	9	-9	-4	5	6	4	2	T	0.95	1.1	15.7895%
0	0	0	0	0	-5	2	3	1	0	0	T	1.05	0.6	42.8571%
0	0	4	7	0	-5	-8	3	4	3	4	T	1.35	0.6	55.5556%
5	6	0	7	0	0	0	5	2	0	7	T	1.1	1.05	4.5455%
5	5	0	5	0	4	-2	8	5	0	5	T	1.15	1.25	8.6957%
0	0	0	0	0	0	0	0	0	4	9	T	1.15	0.9	21.7391%
0	6	0	5	4	0	-5	0	7	0	5	T	1.05	1	4.7619%
2	3	0	0	4	-4	0	0	3	0	2	T	1	1.4	40.0000%
8	8	0	7	0	8	7	7	5	0	5	T	1.05	1.5	42.8571%
0	0	0	1	0	-5	-6	0	3	0	0	T	1.35	0.9	33.3333%
6	7	0	9	0	8	-9	0	7	0	7	T	1.05	1.3	23.8095%
0	4	0	4	0	-4	-7	0	5	7	6	T	0.9	0.85	5.5556%
5	5	0	4	3	-4	-4	5	2	0	5	T	1.75	1.05	40.0000%
0	0	0	2	9	-9	-8	9	8	0	5	T	0.95	1.2	26.3158%
4	7	0	2	2	-4	0	4	4	4	7	T	1.05	1.15	9.5238%
-5	0	0	5	8	-5	-7	0	5	0	0	T	1.05	0.6	42.8571%
0	-1	0	1	0	-1	-1	1	1	1	1	T	1	0.9	10.0000%
-4	-8	0	0	0	0	0	0	0	0	0	T	1.15	0.9	21.7391%
3	6	2	5	5	-8	-8	0	7	3	6	T	0.9	1.2	33.3333%
-1	1	1	0	7	-5	-3	0	7	8	8	T	1.1	1.15	4.5455%
-4	0	1	0	0	-6	-1	6	6	0	5	T	1	1.15	15.0000%
5	5	0	0	0	7	-5	4	6	6	0	T	0.9	1.15	27.7778%
-9	-3	7	3	7	-5	-6	0	4	0	4	T	1.15	1.15	0.0000%
-8	0	0	0	0	0	0	0	0	0	0	T	1.15	1.05	8.6957%
0	0	8	0	7	0	-6	6	0	5	7	T	1.05	0.6	42.8571%
1	7	0	6	1	-8	-7	4	8	3	8	T	0.75	1.2	60.0000%
-5	9	0	6	0	0	-8	0	8	0	9	T	1.15	0.9	21.7391%
-4	-8	0	0	0	-8	-5	7	9	0	8	T	0.95	1.2	26.3158%
1	1	0	7	0	7	0	0	0	0	0	T	1.7	1.05	38.2353%
0	5	0	8	6	7	-7	8	6	3	5	T	1.05	1	4.7619%
0	0	0	0	0	0	-5	1	1	8	8	T	1.05	0.9	14.2857%
1	5	0	5	0	7	-7	0	5	4	6	T	1.1	1	9.0909%
7	7	0	7	0	-7	0	0	0	0	0	T	1.15	1.25	8.6957%
-5	0	5	0	5	9	0	5	7	5	5	T	1.05	1	4.7619%
4	9	0	8	0	6	0	0	0	9	0	T	1.2	1	16.6667%
0	0	5	1	0	7	0	7	7	0	9	T	1.1	1	9.0909%
5	9	0	0	0	9	-5	5	9	9	0	T	1	1.15	15.0000%
5	6	0	5	0	5	-5	5	0	0	0	T	1.35	1.2	11.1111%
2	6	7	0	0	2	-3	0	0	0	0	P	0.95	0.95	0.0000%
-1	0	0	6	8	-7	-6	0	0	5	7	P	0.9	0.9	0.0000%
0	6	0	6	9	0	0	0	0	0	0	P	1.15	1.15	0.0000%
5	9	0	6	6	0	0	4	5	4	7	P	1	1	0.0000%
-5	0	2	0	0	0	-1	5	0	0	0	P	1.05	1.05	0.0000%
0	0	0	0	0	0	0	0	0	4	8	P	0.95	0.9	5.2632%
0	9	0	9	5	9	-9	0	6	0	8	P	1.25	1.3	4.0000%
7	8	3	0	0	8	-8	7	5	0	0	P	1.2	1.15	4.1667%
-6	-5	0	6	0	0	0	7	0	6	5	P	0.95	0.95	0.0000%
1	4	0	8	0	1	-3	0	4	0	0	P	1.1	1.1	0.0000%
2	3	0	2	9	4	-3	4	0	0	4	P	1.2	1.2	0.0000%
0	4	3	5	0	0	-1	0	0	0	2	P	1.35	1.35	0.0000%
0	2	0	0	6	3	-2	0	0	1	3	P	1.05	1	4.7619%
1	1	3	0	2	3	3	4	2	6	6	P	0.65	0.6	7.6923%
2	5	0	3	4	-4	-6	0	5	0	0	P	0.85	0.85	0.0000%
0	7	0	7	0	-8	-6	0	6	7	8	P	1.25	1.2	4.0000%
-3	-3	2	3	9	-3	-7	7	4	4	7	P	1.1	1.15	4.5455%
0	3	0	2	0	-4	-4	4	3	0	8	P	1.4	1.4	0.0000%

# ANEXOS- Resultados Experimentais

x_0	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_10	Set	y	y'	Erro Abs(%)
6	7	0	5	4	5	-6	6	2	6	3	P	1.2	1.2	0.0000%
-6	6	6	4	5	0	-7	5	3	5	5	P	1.1	1.15	4.5455%
-8	7	0	0	0	6	-2	2	7	0	0	P	1.25	1.25	0.0000%
0	0	0	5	0	-2	-1	0	1	0	0	P	0.85	0.9	5.8824%
-2	-1	2	4	2	-5	-7	0	3	3	6	P	0.95	0.9	5.2632%
-2	6	0	3	0	6	-8	7	7	0	0	P	1	1	0.0000%
0	5	4	0	6	-9	-9	9	0	0	0	P	1.25	1.25	0.0000%
0	9	0	6	0	-4	-7	7	9	0	0	P	1	1	0.0000%
-1	-2	2	5	7	-5	-4	5	6	5	7	P	1.15	1.15	0.0000%
0	2	0	2	0	3	3	0	0	0	0	P	1	1	0.0000%
-4	1	1	2	0	4	-4	3	4	4	5	P	0.9	0.9	0.0000%
-4	0	0	6	0	-7	0	8	7	0	8	P	1.05	1.1	4.7619%
0	5	0	4	3	-5	0	5	0	0	0	P	1.05	1.05	0.0000%
4	7	1	7	4	7	0	8	8	4	4	P	1.3	1.5	15.3846%
-6	-1	9	2	0	-6	-6	0	0	8	9	P	1.15	1.3	13.0435%
0	5	0	5	0	-6	0	5	5	0	5	P	1.2	1.15	4.1667%
-2	0	0	0	7	9	-7	2	6	2	8	P	1.05	1.1	4.7619%
-6	0	0	0	0	6	-5	0	6	0	6	P	0.6	0.6	0.0000%
-2	-4	6	0	0	0	-4	2	0	0	6	P	0.6	0.6	0.0000%
0	8	0	8	6	-6	-5	7	0	0	8	P	1.05	1.05	0.0000%
3	7	0	0	0	-8	0	8	6	0	0	P	1.05	1	4.7619%
0	7	0	2	2	-5	-3	0	3	7	0	P	0.85	0.85	0.0000%
-4	9	0	8	0	-9	-1	0	0	0	2	P	1.25	1.25	0.0000%
6	6	0	0	0	6	0	6	8	0	0	P	1.15	1.15	0.0000%
0	0	4	0	9	0	1	1	0	0	0	P	0.9	0.9	0.0000%
0	0	0	5	5	-5	0	0	0	5	9	P	0.95	0.9	5.2632%
-3	8	0	2	0	0	-6	0	0	0	7	P	1.2	1.15	4.1667%
1	4	2	0	0	8	2	8	8	0	8	P	1.1	1.1	0.0000%
0	7	0	0	6	-6	-7	0	4	0	6	P	1.25	1.25	0.0000%
-8	0	6	1	2	1	4	2	3	2	4	P	1.2	1.15	4.1667%
-5	-5	5	5	5	5	5	5	5	5	5	P	1	1	0.0000%
2	4	0	0	0	6	-4	1	0	0	2	P	1.3	1.15	11.5385%
0	8	0	5	0	0	-9	0	9	3	0	P	0.95	1	5.2632%
1	3	0	0	2	2	3	3	3	0	4	P	1	1.15	15.0000%
4	-5	5	6	6	5	0	5	6	6	6	P	1.75	1.5	14.2857%
0	-5	6	0	0	4	-6	0	7	6	6	P	1	1	0.0000%
-6	3	0	2	0	2	-4	0	0	1	2	P	0.95	0.95	0.0000%
0	7	1	3	6	-5	7	3	4	3	1	P	0.95	0.95	0.0000%
1	-1	0	1	0	0	-2	1	0	0	2	P	1.05	1.05	0.0000%
-7	9	8	9	0	0	0	0	0	0	6	P	0.75	0.7	6.6667%
-2	-2	2	6	9	-7	-8	3	5	7	4	P	1.15	1.2	4.3478%
-5	-3	5	0	6	-5	-5	6	7	7	2	P	0.9	0.9	0.0000%
4	7	0	0	0	0	0	4	0	0	0	P	1.25	1.25	0.0000%
7	6	0	5	0	-5	-5	5	5	5	5	P	1.95	1.95	0.0000%
-7	-5	0	4	0	-4	-3	0	4	4	0	P	1.05	1.05	0.0000%
1	5	0	1	0	7	-8	2	8	0	4	P	1.2	1.15	4.1667%
5	4	0	5	0	-6	-5	0	2	0	4	P	1.4	1.4	0.0000%
0	0	3	0	0	0	-3	0	3	2	0	P	0.85	0.9	5.8824%
6	5	1	5	0	6	0	0	5	0	6	P	1.5	1.5	0.0000%
0	8	0	0	0	7	-7	0	8	0	0	P	1	1	0.0000%
3	6	0	8	0	-4	0	7	8	7	4	P	1.05	1	4.7619%
0	0	0	0	0	-5	0	0	0	4	4	P	0.5	0.5	0.0000%
5	8	0	4	0	-8	-1	8	6	7	4	P	1	1	0.0000%
-2	5	0	0	8	6	-3	7	5	0	0	P	1.15	1.15	0.0000%
-4	4	0	4	4	3	-4	0	0	4	4	P	0.95	0.95	0.0000%
0	0	0	6	0	-6	-7	6	6	6	0	P	1.1	1.1	0.0000%

## ANEXOS- Resultados Experimentais

x_0	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_10	Set	y	y'	Erro Abs(%)
-5	3	3	5	3	-5	0	0	5	5	6	P	1.3	1.3	0.0000%
5	5	0	5	0	-5	-5	5	5	5	9	P	1.15	1.15	0.0000%
-6	5	0	5	0	-3	-4	3	3	2	5	P	1.15	1.15	0.0000%
7	6	0	4	0	6	3	5	8	5	0	P	1.15	1.15	0.0000%
3	4	0	4	3	5	-4	3	5	5	4	P	1.3	1.25	3.8462%
0	7	3	0	5	-5	-5	3	2	2	4	P	1.2	1.15	4.1667%
0	5	0	5	0	5	0	0	5	0	3	P	1.25	1.25	0.0000%
5	7	0	0	1	5	-7	8	8	2	0	P	1.1	1.1	0.0000%
1	2	0	2	3	-3	-3	3	0	1	2	P	1.25	1.25	0.0000%
4	6	0	2	0	6	0	0	4	0	6	P	1.05	1.1	4.7619%
-7	7	0	4	0	0	-8	0	8	0	6	P	0.95	0.9	5.2632%
-9	9	0	5	0	-9	-9	0	5	0	0	P	1.35	1.35	0.0000%
-3	3	0	1	0	0	-3	0	3	1	2	P	1.15	1.15	0.0000%
3	5	0	0	0	2	-9	7	9	5	9	P	1.05	1.1	4.7619%
5	3	6	5	5	5	0	6	6	6	7	P	1	1	0.0000%
0	4	0	4	0	7	-2	0	3	0	0	P	1	1	0.0000%
5	6	0	6	0	6	-5	2	4	0	4	P	0.8	0.8	0.0000%
-3	0	0	3	0	-6	-6	5	2	2	6	P	1.4	1.3	7.1429%
-7	0	2	4	0	0	0	9	2	7	9	P	1.05	1.05	0.0000%
-5	4	0	2	0	0	0	0	3	2	0	P	0.95	0.95	0.0000%
-3	6	0	6	5	-4	8	0	0	6	0	P	1.15	1.15	0.0000%
1	5	0	1	0	-2	0	0	0	0	0	P	1.25	1.25	0.0000%
0	9	3	9	0	-5	9	0	5	8	6	P	1.75	1.75	0.0000%
0	0	0	0	0	1	0	0	0	0	8	P	0.9	0.9	0.0000%
6	5	0	9	0	6	-4	6	4	0	4	P	0.7	0.7	0.0000%
0	0	0	9	0	-9	-9	5	9	0	5	P	1.35	1.3	3.7037%
0	8	0	3	9	-5	-5	3	5	0	5	P	1.1	1.1	0.0000%
0	9	0	0	0	9	-3	9	5	0	2	P	1.5	1.5	0.0000%
0	0	8	9	0	-9	-9	5	5	0	0	P	1.75	1.75	0.0000%
-4	4	0	0	0	0	-3	0	4	4	4	P	1.15	1.15	0.0000%
-1	-1	0	0	0	-7	0	1	7	0	4	P	1.1	1.1	0.0000%

Tabela A-51: Árvore de Decisão R - Resultados Modelo Estratégico ME14ADR

### Modelo Estratégico 2015

x_0	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_10	Set	y	y'	Erro Abs(%)
5	8	0	0	0	5	-5	0	0	0	0	T	0.95	1.1	15.7895%
3	7	0	5	0	3	0	0	0	0	0	T	1.8	1.3	27.7778%
-2	-1	7	0	1	0	-5	5	5	5	7	T	1.35	1	25.9259%
-5	0	1	5	0	-9	-5	7	0	5	9	T	0.9	1	11.1111%
7	7	0	6	0	0	-6	0	0	0	6	T	1.5	1.05	30.0000%
-6	6	3	4	0	3	0	4	4	0	0	T	1.05	0.9	14.2857%
-7	8	5	5	7	7	-7	0	0	6	6	T	1	1	0.0000%
-8	6	3	8	5	0	-8	5	3	7	5	T	0.95	1.15	21.0526%
-2	7	0	4	0	-6	-4	0	0	2	4	T	1.05	1	4.7619%
0	0	0	5	4	-3	-1	0	2	0	0	T	1.2	1.65	37.5000%
-1	6	0	2	9	-9	-4	6	6	4	2	T	1.65	1.15	30.3030%
0	0	0	5	0	-7	0	8	7	0	8	T	1	1.4	40.0000%
0	0	0	0	0	-7	3	4	1	0	0	T	1.25	1	20.0000%
-6	-1	9	2	0	8	-6	0	0	8	9	T	0.75	0.9	20.0000%
0	9	0	8	0	6	-8	7	5	7	6	T	1.35	1.15	14.8148%
0	0	6	0	8	6	-5	8	6	6	5	T	0.65	0.9	38.4615%
6	7	0	0	0	-8	0	8	6	0	0	T	1.1	1	9.0909%

# ANEXOS- Resultados Experimentais

x_0	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_10	Set	y	y'	Erro Abs(%)
0	0	0	5	5	-5	0	0	0	5	9	T	1	1.4	40.0000%
3	5	0	1	3	6	-4	1	0	0	2	T	0.8	1	25.0000%
-3	0	0	0	0	2	0	2	6	0	0	T	1.1	1.15	4.5455%
0	-6	0	0	0	0	-5	0	0	0	4	T	1.25	0.9	28.0000%
1	-2	0	5	3	-3	-3	1	0	5	3	T	1	0.9	10.0000%
4	6	4	6	5	8	-6	0	2	0	2	T	1.1	1.15	4.5455%
8	8	0	7	0	8	7	7	5	0	5	T	1.05	1.3	23.8095%
7	7	0	6	0	-6	-6	6	6	6	6	T	1.15	1.3	13.0435%
0	0	5	3	0	-6	3	0	6	3	4	T	1.1	0.9	18.1818%
1	6	0	1	0	7	-8	2	8	0	6	T	1.25	1	20.0000%
0	8	0	0	0	7	-7	0	8	0	0	T	0.8	1.3	62.5000%
5	7	0	5	4	-4	0	8	8	5	7	T	1.1	1.2	9.0909%
-5	6	2	7	1	-7	0	0	6	7	7	T	1	1.3	30.0000%
2	2	0	4	0	5	3	5	8	6	0	T	1.05	1	4.7619%
5	8	0	5	0	0	0	0	0	0	5	T	1.5	1.65	10.0000%
-3	-5	2	3	3	-5	-5	5	5	1	3	T	0.9	1	11.1111%
-2	0	0	2	0	6	-3	0	0	0	0	T	1.15	1	13.0435%
0	7	6	0	5	-5	-5	3	0	3	6	T	1.05	1	4.7619%
5	5	0	0	4	7	-5	4	2	0	4	T	1.6	1.3	18.7500%
6	7	0	3	0	7	0	0	7	2	8	T	0.95	1.1	15.7895%
4	5	7	7	5	5	-5	2	2	6	3	T	1	1.15	15.0000%
-3	3	0	1	0	-5	-4	0	4	3	4	T	1.05	1.35	28.5714%
-5	9	0	7	0	0	-9	0	9	0	9	T	1.25	0.75	40.0000%
6	7	0	3	0	-7	-7	6	2	0	0	T	1.05	1.75	66.6667%
-4	0	0	7	0	-7	-8	7	6	4	7	T	1.15	1.35	17.3913%
5	5	0	0	0	0	-4	3	0	0	0	T	1.1	1	9.0909%
6	7	0	8	0	7	-9	0	7	7	7	T	1.35	1.3	3.7037%
9	0	5	6	8	-6	-8	1	7	0	9	T	1.1	1.15	4.5455%
-7	6	0	1	3	4	-6	7	5	0	5	T	1.3	0.9	30.7692%
2	3	0	3	0	5	-4	0	4	0	0	T	1.55	1.35	12.9032%
0	7	0	4	0	6	0	3	0	0	0	T	1.8	1.1	38.8889%
4	4	0	1	0	7	0	0	3	0	0	T	0.95	1	5.2632%
-1	0	0	4	0	-6	-7	0	0	4	5	P	0.85	0.9	5.8824%
-1	0	0	8	8	-7	-6	0	0	6	7	P	1	0.95	5.0000%
-5	7	0	8	7	8	-8	8	0	0	8	P	1.05	1.05	0.0000%
0	6	0	9	0	0	0	0	0	0	0	P	1.05	1.05	0.0000%
0	5	3	7	0	-3	-5	0	6	4	6	P	1.15	1.15	0.0000%
-6	0	0	5	0	5	0	0	6	0	7	P	0.9	1	11.1111%
-7	0	0	0	0	0	-1	5	0	0	0	P	0.95	1	5.2632%
-3	5	3	1	3	3	3	3	3	4	0	P	0.9	0.9	0.0000%
0	9	0	9	5	9	-9	0	6	0	8	P	1.15	1.15	0.0000%
7	-5	5	0	7	0	-5	0	7	0	0	P	0.75	0.75	0.0000%
0	0	7	7	6	0	-8	7	8	6	7	P	1.15	1.15	0.0000%
-6	-5	0	6	0	0	0	7	0	6	5	P	1.1	1.1	0.0000%
-3	0	0	3	4	0	-4	3	0	0	0	P	1	1	0.0000%
0	4	3	5	0	0	-1	0	0	0	4	P	1.7	1.65	2.9412%
2	2	0	2	6	3	-4	0	0	4	3	P	1	1	0.0000%
2	5	0	3	3	-6	-7	0	4	0	0	P	0.95	0.95	0.0000%
-3	-3	2	4	9	-4	-7	7	4	4	7	P	1.05	1.1	4.7619%
6	7	0	5	4	5	-6	6	2	6	3	P	1.45	1.45	0.0000%
-8	0	0	8	5	0	-4	6	7	7	8	P	0.95	1	5.2632%
-1	-1	2	5	2	-5	-7	0	8	3	6	P	1	1	0.0000%
-2	6	0	8	0	7	-7	7	8	0	0	P	1.15	1.15	0.0000%
0	5	4	0	6	-9	-9	9	0	0	0	P	1.05	1.05	0.0000%
0	9	0	6	0	-4	-7	7	9	0	0	P	0.75	0.75	0.0000%
3	5	0	5	6	-7	-5	0	3	7	7	P	1.05	1.05	0.0000%

# ANEXOS- Resultados Experimentais

x_0	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_10	Set	y	y'	Erro Abs(%)
0	-5	5	6	0	5	0	5	0	0	7	P	0.8	0.9	12.5000%
0	2	0	2	0	3	3	0	2	0	0	P	1	1	0.0000%
-5	2	2	4	0	6	-5	5	4	7	8	P	1.2	1.2	0.0000%
0	5	0	4	4	-7	0	5	0	0	0	P	1.1	1.1	0.0000%
5	8	1	8	5	8	0	9	9	4	4	P	1.3	1.3	0.0000%
0	0	4	7	0	-5	-8	3	4	3	4	P	0.95	1	5.2632%
-2	0	0	0	0	9	-7	2	5	2	8	P	1.2	1.2	0.0000%
8	8	0	8	0	0	0	5	2	0	0	P	1.25	1.3	4.0000%
0	8	0	8	0	8	-7	3	6	5	7	P	1	1	0.0000%
0	0	0	0	0	-7	0	0	8	0	0	P	1.15	1.15	0.0000%
-4	9	0	8	0	-9	-1	0	0	0	2	P	1.15	1.15	0.0000%
5	5	0	0	0	9	-9	6	9	0	9	P	0.6	0.6	0.0000%
-4	5	0	0	0	5	0	8	5	0	5	P	1.15	1.15	0.0000%
-4	-7	9	9	0	-6	6	2	7	2	3	P	1.1	1.1	0.0000%
0	6	0	6	0	6	0	6	8	0	0	P	1.05	1.05	0.0000%
1	1	0	7	0	0	-2	2	0	0	2	P	0.9	0.95	5.5556%
-9	-8	1	8	5	0	0	7	0	8	7	P	1.25	1.25	0.0000%
-5	0	0	3	4	-4	-8	0	0	4	9	P	1	1	0.0000%
0	0	0	0	0	0	0	0	9	9	9	P	1.1	1.15	4.5455%
0	7	0	8	6	-6	-7	0	4	5	6	P	1	1	0.0000%
-7	0	7	2	4	2	6	5	6	3	7	P	1.7	1.7	0.0000%
5	0	5	0	0	-5	-5	6	6	5	5	P	1.05	1.05	0.0000%
5	5	0	8	0	6	0	5	4	0	5	P	1.15	1.15	0.0000%
-5	-5	5	5	5	5	5	5	5	0	5	P	1	1	0.0000%
4	9	0	8	0	0	0	0	9	0	0	P	1.4	1.4	0.0000%
2	-2	0	0	1	2	2	3	2	0	4	P	0.95	1	5.2632%
2	3	0	0	4	-4	0	0	3	0	2	P	1	1	0.0000%
0	0	1	2	5	7	-7	0	7	1	1	P	0.95	0.95	0.0000%
-6	3	0	2	0	2	-4	0	0	1	2	P	1.15	1.15	0.0000%
5	-5	0	6	0	6	8	0	9	0	9	P	1.05	1	4.7619%
-6	0	4	4	4	6	-6	7	3	3	6	P	1	1	0.0000%
-7	7	1	0	3	8	-8	8	5	5	7	P	1.15	1.15	0.0000%
-5	7	5	7	6	-6	-6	6	7	6	1	P	1	1	0.0000%
-6	-2	0	8	0	-8	-9	8	7	8	0	P	0.85	0.85	0.0000%
-6	-5	0	5	0	-4	-3	0	4	5	0	P	0.95	1	5.2632%
2	6	0	9	0	7	-6	5	1	9	7	P	0.9	0.9	0.0000%
0	7	2	6	0	-7	-6	5	6	6	0	P	1.15	1.15	0.0000%
1	4	0	3	0	-5	-8	0	7	8	7	P	1	1	0.0000%
6	5	0	6	0	-6	-6	0	7	5	7	P	1.15	1.15	0.0000%
0	9	0	4	0	-1	-3	0	0	0	0	P	0.95	1	5.2632%
0	0	0	6	0	0	0	0	2	0	6	P	1.35	1.35	0.0000%
3	7	0	8	0	-8	0	7	3	9	5	P	1.05	1.05	0.0000%
-1	0	0	4	9	-9	-8	9	8	9	5	P	1.05	1.05	0.0000%
0	8	0	2	0	-8	-3	4	6	8	4	P	1	1	0.0000%
-3	6	0	0	7	6	-6	2	5	0	0	P	0.9	0.9	0.0000%
0	0	0	3	0	-2	-3	6	3	2	4	P	1.1	1.1	0.0000%
-3	6	1	4	0	7	0	0	0	6	7	P	1.05	1	4.7619%
-4	4	0	4	5	4	-5	0	0	5	5	P	1.3	1.3	0.0000%
-5	0	0	6	8	-5	-7	0	5	0	0	P	1.3	1.3	0.0000%
-7	8	0	8	0	9	0	0	7	7	7	P	1.05	1	4.7619%
0	0	0	7	0	-7	-8	7	7	7	0	P	1.25	1.3	4.0000%
-7	-7	0	0	0	0	0	0	0	0	0	P	1.1	1.1	0.0000%
5	5	0	5	0	-5	-5	5	5	5	9	P	1.2	1.2	0.0000%
3	6	2	5	8	-8	-8	0	4	3	6	P	1.2	1.2	0.0000%
3	4	0	4	3	5	-4	3	5	5	4	P	1	1	0.0000%
5	5	0	5	5	5	-5	0	5	6	9	P	1.25	1.2	4.0000%

## ANEXOS- Resultados Experimentais

x_0	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_10	Set	y	y'	Erro Abs(%)
8	5	0	0	0	7	0	7	0	8	0	P	1.2	1.2	0.0000%
5	7	0	4	0	-6	0	5	4	0	0	P	1	1	0.0000%
2	0	4	0	0	-6	-1	6	7	0	6	P	0.9	0.9	0.0000%
0	5	0	5	0	5	0	0	0	0	3	P	1.3	1.3	0.0000%
-5	5	0	4	0	9	-7	4	7	7	0	P	1.05	1.05	0.0000%
0	0	0	7	0	0	-6	7	8	0	0	P	1.15	1.15	0.0000%
-5	7	0	0	4	6	-7	7	7	0	0	P	1.3	1.3	0.0000%
-3	0	0	4	0	0	-4	3	5	0	0	P	1.15	1.15	0.0000%
-6	6	5	7	0	0	-7	3	4	7	7	P	1.3	1.3	0.0000%
-7	7	0	5	0	0	-8	0	8	0	6	P	1.05	1	4.7619%
0	4	0	5	0	-5	-6	5	6	6	5	P	1.6	1.65	3.1250%
1	4	0	8	0	7	-6	4	6	1	6	P	0.75	0.75	0.0000%
5	6	0	6	0	6	-5	2	4	0	4	P	1.15	1.15	0.0000%
3	0	0	5	3	-5	-6	7	6	6	6	P	1.4	1.4	0.0000%
1	1	0	8	0	7	0	5	7	0	0	P	1.15	1.15	0.0000%
0	8	0	7	8	-8	-8	6	7	2	7	P	1.3	1.35	3.8462%
0	0	7	0	0	-6	-8	9	7	0	9	P	1.15	1.15	0.0000%
0	5	0	8	2	7	-7	8	4	7	5	P	1.2	1.15	4.1667%
0	5	0	2	0	0	0	0	3	3	0	P	1.05	1	4.7619%
0	0	0	2	0	-3	0	2	4	0	3	P	1.35	1.35	0.0000%
8	7	0	0	9	2	-9	0	7	5	9	P	1.15	1.15	0.0000%
0	0	0	0	0	0	-5	1	8	8	8	P	1.1	1.1	0.0000%
-5	5	0	7	0	-9	-7	7	3	6	8	P	1.9	1.9	0.0000%
0	8	0	0	0	7	-9	8	0	8	9	P	1.2	1.15	4.1667%
4	8	0	2	0	-6	-7	0	3	0	5	P	1.75	1.75	0.0000%
7	7	0	7	0	7	0	7	0	0	0	P	1	1.05	5.0000%
0	5	0	0	0	5	-5	5	0	5	0	P	1.2	1.2	0.0000%
-5	0	0	0	0	0	-9	8	0	8	0	P	0.65	0.65	0.0000%
5	9	0	8	0	6	0	0	0	9	0	P	1.05	1.05	0.0000%
5	9	0	0	0	9	-5	5	9	3	0	P	1.1	1.1	0.0000%
6	9	0	6	5	-9	9	4	0	5	6	P	1.2	1.15	4.1667%
3	9	0	2	0	9	-3	9	5	0	5	P	1.15	1.1	4.3478%
5	9	0	5	0	-5	-9	0	0	5	5	P	1.9	1.9	0.0000%
0	-3	0	0	0	0	-3	0	0	0	4	P	0.95	0.9	5.2632%
0	0	0	0	0	9	-9	9	9	0	0	P	1.25	1.2	4.0000%
7	6	0	5	0	8	-5	5	0	0	0	P	1.25	1.3	4.0000%
-1	-1	0	0	0	-7	0	1	7	0	4	P	1	1	0.0000%

Tabela A-52: Arvore de Decisão R - Resultados Modelo Estratégico ME15ADR

### Modelo Estratégico 2013 – Conjunto Teste 2014

x_0	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_10	Set	y	y'	Erro Abs(%)
2	6	7	0	0	2	-3	0	0	0	0	T	0.95	0.85	10.5263%
-1	0	0	6	8	-7	-6	0	0	5	7	T	0.9	1.25	38.8889%
0	6	0	6	9	0	0	0	0	0	0	T	1.15	0.95	17.3913%
5	9	0	6	6	0	0	4	5	4	7	T	1	1.2	20.0000%
-5	0	2	0	0	0	-1	5	0	0	0	T	1.05	1	4.7619%
0	0	0	0	0	0	0	0	0	4	8	T	0.95	0.95	0.0000%
0	9	0	9	5	9	-9	0	6	0	8	T	1.25	1.05	16.0000%
7	8	3	0	0	8	-8	7	5	0	0	T	1.2	1.05	12.5000%
-6	-5	0	6	0	0	0	7	0	6	5	T	0.95	1	5.2632%
1	4	0	8	0	1	-3	0	4	0	0	T	1.1	1.1	0.0000%
2	3	0	2	9	4	-3	4	0	0	4	T	1.2	1.25	4.1667%



# ANEXOS- Resultados Experimentais

x_0	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_10	Set	y	y'	Erro Abs(%)
0	4	3	5	0	0	-1	0	0	0	2	T	1.35	0.95	29.6296%
0	2	0	0	6	3	-2	0	0	1	3	T	1.05	0.65	38.0952%
1	1	3	0	2	3	3	4	2	6	6	T	0.65	1.4	115.3846%
2	5	0	3	4	-4	-6	0	5	0	0	T	0.85	1	17.6471%
0	7	0	7	0	-8	-6	0	6	7	8	T	1.25	1.2	4.0000%
-3	-3	2	3	9	-3	-7	7	4	4	7	T	1.1	1.1	0.0000%
0	3	0	2	0	-4	-4	4	3	0	8	T	1.4	1.6	14.2857%
6	7	0	5	4	5	-6	6	2	6	3	T	1.2	1.2	0.0000%
-6	6	6	4	5	0	-7	5	3	5	5	T	1.1	1.05	4.5455%
-8	7	0	0	0	6	-2	2	7	0	0	T	1.25	0.7	44.0000%
0	0	0	5	0	-2	-1	0	1	0	0	T	0.85	1.15	35.2941%
-2	-1	2	4	2	-5	-7	0	3	3	6	T	0.95	1.2	26.3158%
-2	6	0	3	0	6	-8	7	7	0	0	T	1	1.2	20.0000%
0	5	4	0	6	-9	-9	9	0	0	0	T	1.25	0.75	40.0000%
0	9	0	6	0	-4	-7	7	9	0	0	T	1	1.2	20.0000%
-1	-2	2	5	7	-5	-4	5	6	5	7	T	1.15	1.2	4.3478%
0	2	0	2	0	3	3	0	0	0	0	T	1	0.8	20.0000%
-4	1	1	2	0	4	-4	3	4	4	5	T	0.9	1.2	33.3333%
-4	0	0	6	0	-7	0	8	7	0	8	T	1.05	1.2	14.2857%
0	5	0	4	3	-5	0	5	0	0	0	T	1.05	0.95	9.5238%
4	7	1	7	4	7	0	8	8	4	4	T	1.3	1.2	7.6923%
-6	-1	9	2	0	-6	-6	0	0	8	9	T	1.15	1	13.0435%
0	5	0	5	0	-6	0	5	5	0	5	T	1.2	1.2	0.0000%
-2	0	0	0	7	9	-7	2	6	2	8	T	1.05	0.7	33.3333%
-6	0	0	0	0	6	-5	0	6	0	6	T	0.6	1.05	75.0000%
-2	-4	6	0	0	0	-4	2	0	0	6	T	0.6	1	66.6667%
0	8	0	8	6	-6	-5	7	0	0	8	T	1.05	1.2	14.2857%
3	7	0	0	0	-8	0	8	6	0	0	T	1.05	0.9	14.2857%
0	7	0	2	2	-5	-3	0	3	7	0	T	0.85	1.9	123.5294%
-4	9	0	8	0	-9	-1	0	0	0	2	T	1.25	1.4	12.0000%
6	6	0	0	0	6	0	6	8	0	0	T	1.15	1.05	8.6957%
0	0	4	0	9	0	1	1	0	0	0	T	0.9	0.65	27.7778%
0	0	0	5	5	-5	0	0	0	5	9	T	0.95	1	5.2632%
-3	8	0	2	0	0	-6	0	0	0	7	T	1.2	1.05	12.5000%
1	4	2	0	0	8	2	8	8	0	8	T	1.1	0.8	27.2727%
0	7	0	0	6	-6	-7	0	4	0	6	T	1.25	1.1	12.0000%
-8	0	6	1	2	1	4	2	3	2	4	T	1.2	0.7	41.6667%
-5	-5	5	5	5	5	5	5	5	5	5	T	1	0.95	5.0000%
2	4	0	0	0	6	-4	1	0	0	2	T	1.3	1.4	7.6923%
0	8	0	5	0	0	-9	0	9	3	0	T	0.95	1.2	26.3158%
1	3	0	0	2	2	3	3	3	0	4	T	1	0.95	5.0000%
4	-5	5	6	6	5	0	5	6	6	6	T	1.75	1.2	31.4286%
0	-5	6	0	0	4	-6	0	7	6	6	T	1	0.95	5.0000%
-6	3	0	2	0	2	-4	0	0	1	2	T	0.95	0.95	0.0000%
0	7	1	3	6	-5	7	3	4	3	1	T	0.95	0.95	0.0000%
1	-1	0	1	0	0	-2	1	0	0	2	T	1.05	1.15	9.5238%
-7	9	8	9	0	0	0	0	0	0	6	T	0.75	1.4	86.6667%
-2	-2	2	6	9	-7	-8	3	5	7	4	T	1.15	1.1	4.3478%
-5	-3	5	0	6	-5	-5	6	7	7	2	T	0.9	0.95	5.5556%
4	7	0	0	0	0	0	4	0	0	0	T	1.25	0.7	44.0000%
7	6	0	5	0	-5	-5	5	5	5	5	T	1.95	0.55	71.7949%
-7	-5	0	4	0	-4	-3	0	4	4	0	T	1.05	1.1	4.7619%
1	5	0	1	0	7	-8	2	8	0	4	T	1.2	0.7	41.6667%
5	4	0	5	0	-6	-5	0	2	0	4	T	1.4	1	28.5714%
0	0	3	0	0	0	-3	0	3	2	0	T	0.85	0.7	17.6471%
6	5	1	5	0	6	0	0	5	0	6	T	1.5	1.9	26.6667%

# ANEXOS- Resultados Experimentais

x_0	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_10	Set	y	y'	Erro Abs(%)
0	8	0	0	0	7	-7	0	8	0	0	T	1	1.1	10.0000%
3	6	0	8	0	-4	0	7	8	7	4	T	1.05	1.25	19.0476%
0	0	0	0	0	-5	0	0	0	4	4	T	0.5	0.95	90.0000%
5	8	0	4	0	-8	-1	8	6	7	4	T	1	1	0.0000%
-2	5	0	0	8	6	-3	7	5	0	0	T	1.15	0.9	21.7391%
-4	4	0	4	4	3	-4	0	0	4	4	T	0.95	1	5.2632%
0	0	0	6	0	-6	-7	6	6	6	0	T	1.1	1.25	13.6364%
-5	3	3	5	3	-5	0	0	5	5	6	T	1.3	1.2	7.6923%
5	5	0	5	0	-5	-5	5	5	5	9	T	1.15	1.1	4.3478%
-6	5	0	5	0	-3	-4	3	3	2	5	T	1.15	1.2	4.3478%
7	6	0	4	0	6	3	5	8	5	0	T	1.15	1.25	8.6957%
3	4	0	4	3	5	-4	3	5	5	4	T	1.3	1.05	19.2308%
0	7	3	0	5	-5	-5	3	2	2	4	T	1.2	0.7	41.6667%
0	5	0	5	0	5	0	0	5	0	3	T	1.25	1.15	8.0000%
5	7	0	0	1	5	-7	8	8	2	0	T	1.1	1.05	4.5455%
1	2	0	2	3	-3	-3	3	0	1	2	T	1.25	0.95	24.0000%
4	6	0	2	0	6	0	0	4	0	6	T	1.05	1.9	80.9524%
-7	7	0	4	0	0	-8	0	8	0	6	T	0.95	1.05	10.5263%
-9	9	0	5	0	-9	-9	0	5	0	0	T	1.35	1.05	22.2222%
-3	3	0	1	0	0	-3	0	3	1	2	T	1.15	0.95	17.3913%
3	5	0	0	0	2	-9	7	9	5	9	T	1.05	0.8	23.8095%
5	3	6	5	5	5	0	6	6	6	7	T	1	1.2	20.0000%
0	4	0	4	0	7	-2	0	3	0	0	T	1	1.15	15.0000%
5	6	0	6	0	6	-5	2	4	0	4	T	0.8	1.2	50.0000%
-3	0	0	3	0	-6	-6	5	2	2	6	T	1.4	0.75	46.4286%
-7	0	2	4	0	0	0	9	2	7	9	T	1.05	0.75	28.5714%
-5	4	0	2	0	0	0	0	3	2	0	T	0.95	1.3	36.8421%
-3	6	0	6	5	-4	8	0	0	6	0	T	1.15	0.95	17.3913%
1	5	0	1	0	-2	0	0	0	0	0	T	1.25	1.1	12.0000%
0	9	3	9	0	-5	9	0	5	8	6	T	1.75	1	42.8571%
0	0	0	0	0	1	0	0	0	0	8	T	0.9	1.15	27.7778%
6	5	0	9	0	6	-4	6	4	0	4	T	0.7	1.1	57.1429%
0	0	0	9	0	-9	-9	5	9	0	5	T	1.35	1.1	18.5185%
0	8	0	3	9	-5	-5	3	5	0	5	T	1.1	0.75	31.8182%
0	9	0	0	0	9	-3	9	5	0	2	T	1.5	0.9	40.0000%
0	0	8	9	0	-9	-9	5	5	0	0	T	1.75	1.1	37.1429%
-4	4	0	0	0	0	-3	0	4	4	4	T	1.15	0.95	17.3913%
-1	-1	0	0	0	-7	0	1	7	0	4	T	1.1	0.95	13.6364%
-6	0	0	5	0	5	0	0	6	0	7	T	1.05	1.2	14.2857%
-2	-1	7	0	1	0	-4	4	3	1	7	T	0.85	1	17.6471%
-5	-1	5	4	2	-6	-4	3	2	4	6	T	0.55	1.2	118.1818%
1	4	0	3	0	0	0	3	6	0	0	T	1.15	1.05	8.6957%
0	4	0	2	0	-5	-4	0	0	2	3	T	0.95	0.95	0.0000%
-5	7	5	7	5	6	-5	3	0	4	5	T	1	1.05	5.0000%
-6	6	0	0	8	0	-2	4	0	0	3	T	0.9	0.7	22.2222%
5	4	0	0	0	0	-1	6	6	0	5	T	0.85	0.95	11.7647%
6	0	5	0	0	-5	-6	6	0	0	5	T	0.9	1.35	50.0000%
-7	-2	6	0	0	-4	0	0	6	7	9	T	0.75	0.95	26.6667%
-7	0	8	7	7	0	0	0	0	0	3	T	1.15	1.25	8.6957%
-3	0	0	2	7	3	-5	5	4	5	6	T	1.1	1.1	0.0000%
2	4	0	5	0	5	-5	5	1	4	2	T	1.5	1.25	16.6667%
0	7	2	6	0	-7	-6	5	5	0	0	T	1.05	1.2	14.2857%
0	0	0	4	0	0	0	0	2	0	5	T	1.1	1.2	9.0909%
3	1	0	4	0	-4	-3	4	3	0	0	T	1.2	1	16.6667%
0	0	0	2	0	-1	-3	4	2	0	1	T	1.25	1.05	16.0000%
1	2	0	4	3	-3	-6	4	4	5	0	T	1.1	1.05	4.5455%

# ANEXOS- Resultados Experimentais

x_0	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_10	Set	y	y'	Erro Abs(%)
-6	3	8	1	6	0	-2	1	3	7	7	T	1	0.95	5.0000%
0	0	0	0	5	0	0	0	5	6	9	T	1.05	0.95	9.5238%
-6	-3	0	0	0	0	0	0	0	0	0	T	1.3	1.2	7.6923%
0	0	0	7	0	0	-6	7	6	0	0	T	1	1.1	10.0000%
-6	0	5	7	0	0	-7	3	4	4	7	T	1.25	1.2	4.0000%
1	3	0	7	0	6	-5	4	6	2	5	T	1.1	1.6	45.4545%
-4	0	0	4	1	-3	-4	4	2	1	4	T	1.5	1.05	30.0000%
0	0	0	5	0	-6	-7	7	5	0	9	T	1.2	1.1	8.3333%
5	6	0	1	0	0	4	0	0	0	0	T	1.35	0.85	37.0370%
0	5	9	0	0	5	-5	5	0	5	0	T	1	1.4	40.0000%
4	5	0	5	2	7	-7	8	3	5	7	T	1.3	1.1	15.3846%
-1	-3	0	4	0	-6	-6	0	0	4	5	T	1.55	1	35.4839%
-3	4	3	1	3	3	3	3	3	3	0	T	0.85	0.95	11.7647%
-2	0	0	0	3	0	-6	6	0	0	0	T	1.2	1.05	12.5000%
-2	0	0	0	0	0	-1	0	3	0	4	T	0.95	0.95	0.0000%
8	8	0	5	6	4	-5	7	4	0	0	T	1.1	0.55	50.0000%
-8	0	5	5	0	0	-4	6	7	7	8	T	1	0.95	5.0000%
-1	6	0	2	9	-9	-4	5	6	4	2	T	0.95	1.2	26.3158%
0	0	0	0	0	-5	2	3	1	0	0	T	1.05	0.95	9.5238%
0	0	4	7	0	-5	-8	3	4	3	4	T	1.35	0.9	33.3333%
5	6	0	7	0	0	0	5	2	0	7	T	1.1	1.4	27.2727%
5	5	0	5	0	4	-2	8	5	0	5	T	1.15	1.2	4.3478%
0	0	0	0	0	0	0	0	0	4	9	T	1.15	0.95	17.3913%
0	6	0	5	4	0	-5	0	7	0	5	T	1.05	1.2	14.2857%
2	3	0	0	4	-4	0	0	3	0	2	T	1	0.95	5.0000%
8	8	0	7	0	8	7	7	5	0	5	T	1.05	1.25	19.0476%
0	0	0	1	0	-5	-6	0	3	0	0	T	1.35	1.05	22.2222%
6	7	0	9	0	8	-9	0	7	0	7	T	1.05	1.05	0.0000%
0	4	0	4	0	-4	-7	0	5	7	6	T	0.9	1.2	33.3333%
5	5	0	4	3	-4	-4	5	2	0	5	T	1.75	0.75	57.1429%
0	0	0	2	9	-9	-8	9	8	0	5	T	0.95	1.1	15.7895%
4	7	0	2	2	-4	0	4	4	4	7	T	1.05	1.9	80.9524%
-5	0	0	5	8	-5	-7	0	5	0	0	T	1.05	0.9	14.2857%
0	-1	0	1	0	-1	-1	1	1	1	1	T	1	0.95	5.0000%
-4	-8	0	0	0	0	0	0	0	0	0	T	1.15	1.2	4.3478%
3	6	2	5	5	-8	-8	0	7	3	6	T	0.9	1.2	33.3333%
-1	1	1	0	7	-5	-3	0	7	8	8	T	1.1	0.95	13.6364%
-4	0	1	0	0	-6	-1	6	6	0	5	T	1	1	0.0000%
5	5	0	0	0	7	-5	4	6	6	0	T	0.9	0.8	11.1111%
-9	-3	7	3	7	-5	-6	0	4	0	4	T	1.15	1.1	4.3478%
-8	0	0	0	0	0	0	0	0	0	0	T	1.15	1	13.0435%
0	0	8	0	7	0	-6	6	0	5	7	T	1.05	1.4	33.3333%
1	7	0	6	1	-8	-7	4	8	3	8	T	0.75	1.2	60.0000%
-5	9	0	6	0	0	-8	0	8	0	9	T	1.15	1.05	8.6957%
-4	-8	0	0	0	-8	-5	7	9	0	8	T	0.95	1.05	10.5263%
1	1	0	7	0	7	0	0	0	0	0	T	1.7	1.15	32.3529%
0	5	0	8	6	7	-7	8	6	3	5	T	1.05	1.1	4.7619%
0	0	0	0	0	0	-5	1	1	8	8	T	1.05	1.15	9.5238%
1	5	0	5	0	7	-7	0	5	4	6	T	1.1	1.2	9.0909%
7	7	0	7	0	-7	0	0	0	0	0	T	1.15	1.4	21.7391%
-5	0	5	0	5	9	0	5	7	5	5	T	1.05	0.95	9.5238%
4	9	0	8	0	6	0	0	0	9	0	T	1.2	1.4	16.6667%
0	0	5	1	0	7	0	7	7	0	9	T	1.1	0.8	27.2727%
5	9	0	0	0	9	-5	5	9	9	0	T	1	0.8	20.0000%
5	6	0	5	0	5	-5	5	0	0	0	T	1.35	1.2	11.1111%
3	7	0	5	0	7	-6	7	7	4	2	P	1.05	1.05	0.0000%

# ANEXOS- Resultados Experimentais

x_0	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_10	Set	y	y'	Erro Abs(%)
0	0	5	0	0	2	0	2	0	0	0	P	0.85	0.8	5.8824%
-3	0	0	5	8	-6	-3	0	0	0	6	P	1.25	1.25	0.0000%
0	6	0	6	4	0	0	0	0	0	0	P	0.9	0.95	5.5556%
5	9	0	6	6	0	0	4	5	4	7	P	1.15	1.2	4.3478%
-3	3	3	1	3	3	3	3	3	2	0	P	0.65	0.7	7.6923%
-6	-5	0	6	0	0	0	7	0	6	5	P	1	1	0.0000%
7	7	0	6	0	0	-6	0	0	0	6	P	0.55	0.55	0.0000%
2	0	0	4	4	-4	-1	0	0	1	3	P	0.95	0.95	0.0000%
0	6	0	5	0	-6	-3	0	6	4	4	P	1	1	0.0000%
2	4	0	3	0	0	0	3	4	0	0	P	1	1.05	5.0000%
0	2	0	0	0	0	-3	0	0	0	0	P	1.15	1.15	0.0000%
-7	5	8	1	5	5	-4	0	0	2	2	P	1.05	1.1	4.7619%
-4	-3	2	3	9	-3	-6	7	3	3	6	P	1.15	1.1	4.3478%
-1	-1	2	0	0	-1	-1	0	0	2	2	P	0.75	0.7	6.6667%
-4	-5	4	4	0	4	-4	0	4	0	0	P	0.95	0.95	0.0000%
6	7	0	5	4	5	-6	6	2	6	3	P	1.15	1.2	4.3478%
-8	7	0	0	0	5	0	2	7	0	0	P	0.7	0.7	0.0000%
-2	-1	6	4	2	-5	-7	0	3	3	4	P	1.05	1.1	4.7619%
0	5	4	0	6	-9	-9	9	0	0	0	P	0.75	0.75	0.0000%
0	0	0	0	5	0	-3	0	2	0	0	P	0.7	0.65	7.1429%
0	2	0	2	0	3	3	0	2	0	0	P	1.3	1.3	0.0000%
-1	6	0	2	9	-9	-3	5	6	3	2	P	1.2	1.2	0.0000%
0	5	0	4	3	-5	0	5	0	0	0	P	0.95	0.95	0.0000%
3	6	1	3	3	6	0	7	3	4	4	P	1.85	1.9	2.7027%
-6	-1	9	2	0	-6	-6	0	0	8	9	P	1.05	1	4.7619%
0	5	0	3	0	5	-4	3	4	0	5	P	1.2	1.2	0.0000%
0	4	0	4	0	-5	0	5	4	0	5	P	1.2	1.2	0.0000%
-2	-3	6	0	0	0	-7	2	0	0	5	P	1.05	1.05	0.0000%
2	6	0	0	0	-8	0	8	6	0	0	P	0.9	0.9	0.0000%
0	7	0	0	2	-5	-2	0	0	7	0	P	1.35	1.35	0.0000%
6	2	9	0	0	0	-1	6	3	0	2	P	1	1	0.0000%
-3	-3	0	5	4	-6	4	8	4	1	6	P	1.25	1.2	4.0000%
-1	0	5	0	9	0	2	1	0	0	0	P	1.05	1.05	0.0000%
4	7	0	4	0	-8	-4	0	0	0	4	P	1.9	1.9	0.0000%
-9	0	9	5	5	-5	0	0	0	5	9	P	0.8	0.8	0.0000%
-8	-6	1	8	5	0	0	7	0	8	7	P	0.75	0.8	6.6667%
-5	0	1	0	0	0	2	0	0	0	0	P	0.75	0.8	6.6667%
6	0	5	0	0	-5	-5	6	0	0	5	P	1.35	1.35	0.0000%
1	3	0	0	0	-4	-5	4	4	0	5	P	1	1.05	5.0000%
2	3	0	0	4	-4	0	0	3	0	2	P	0.95	0.95	0.0000%
0	0	0	0	0	0	0	2	3	0	4	P	1	0.95	5.0000%
0	7	1	3	5	-5	7	3	4	3	1	P	1	0.95	5.0000%
-4	6	0	6	0	-6	-6	6	5	6	6	P	1.05	1.05	0.0000%
1	0	0	1	0	0	-1	1	0	1	1	P	1.15	1.15	0.0000%
-5	0	0	0	0	0	-5	6	0	0	5	P	1	1.05	5.0000%
-2	-1	0	0	2	3	0	0	0	0	4	P	0.95	1	5.2632%
0	0	0	4	0	-3	-6	0	5	7	0	P	1.1	1.1	0.0000%
4	7	0	0	0	0	0	4	0	0	0	P	0.75	0.7	6.6667%
0	5	0	4	0	-4	-4	4	4	4	4	P	0.9	0.9	0.0000%
-1	0	8	2	0	-6	4	0	5	6	1	P	0.9	0.9	0.0000%
1	4	0	7	0	6	-8	2	8	0	0	P	1.05	1.05	0.0000%
1	3	0	3	0	-3	-6	0	5	5	5	P	1.2	1.2	0.0000%
2	4	0	7	0	-5	-3	0	2	0	4	P	1	1	0.0000%
0	0	5	3	0	0	-2	0	3	4	0	P	1.2	1.15	4.1667%
5	5	0	4	3	-4	-4	5	2	0	5	P	0.75	0.75	0.0000%
-1	0	0	1	9	-9	-7	9	7	0	5	P	1.15	1.15	0.0000%

# ANEXOS- Resultados Experimentais

x_0	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_10	Set	y	y'	Erro Abs(%)
4	7	0	0	0	4	4	0	0	0	2	P	0.85	0.85	0.0000%
-2	3	0	0	6	9	-9	7	5	0	0	P	1.05	1.05	0.0000%
-4	4	0	4	3	2	-3	0	0	3	3	P	0.9	0.95	5.5556%
0	0	0	5	0	-5	-6	5	5	5	0	P	1.2	1.25	4.1667%
3	7	0	9	0	2	-8	6	3	3	4	P	1.2	1.2	0.0000%
0	-1	0	1	0	-1	-1	1	1	1	1	P	0.9	0.95	5.5556%
0	2	6	6	5	-2	0	0	4	4	5	P	1.15	1.2	4.3478%
7	6	0	4	0	8	3	5	8	5	0	P	1.3	1.25	3.8462%
-8	5	0	0	0	3	-4	6	0	0	8	P	0.85	0.9	5.8824%
3	6	2	4	5	-8	-8	0	4	3	6	P	1.15	1.2	4.3478%
-3	6	0	4	0	-3	-4	4	7	0	4	P	1.2	1.25	4.1667%
0	3	0	4	0	0	0	0	0	0	2	P	0.8	0.8	0.0000%
-3	-3	0	0	0	0	0	0	0	0	0	P	1.25	1.2	4.0000%
-3	-4	2	3	3	-5	-5	5	5	1	3	P	1.3	1.25	3.8462%
0	0	0	0	0	4	-1	0	0	3	0	P	1.2	1.15	4.1667%
3	1	0	0	0	-4	0	5	2	0	0	P	0.9	0.95	5.5556%
6	5	0	0	0	3	4	5	2	0	7	P	1.05	1.05	0.0000%
-5	0	5	7	0	0	-7	3	4	4	7	P	1.2	1.2	0.0000%
-8	0	0	0	0	0	0	0	0	0	0	P	1	1	0.0000%
-7	7	0	3	0	0	-7	0	8	0	6	P	1.1	1.05	4.5455%
0	0	0	0	5	0	0	0	0	0	0	P	0.6	0.65	8.3333%
-5	9	0	5	0	0	-7	0	7	0	9	P	1.1	1.05	4.5455%
5	6	0	6	0	6	-5	2	4	0	4	P	1.25	1.2	4.0000%
1	1	0	6	0	7	0	0	0	0	0	P	1.15	1.15	0.0000%
0	5	0	0	0	0	-5	3	0	0	0	P	0.7	0.7	0.0000%
0	6	0	0	0	7	-9	8	0	6	9	P	1.15	1.15	0.0000%
-5	5	0	4	4	5	-5	6	6	6	5	P	0.95	0.95	0.0000%
0	0	0	9	0	-9	0	9	0	0	0	P	0.8	0.8	0.0000%
2	5	0	4	0	2	-6	0	5	5	5	P	1.9	1.9	0.0000%
7	7	0	7	0	-7	0	0	0	0	0	P	1.55	1.4	9.6774%
0	0	0	0	0	1	0	0	0	0	8	P	1.1	1.15	4.5455%
0	0	0	0	0	8	-9	8	9	0	0	P	1.2	1.15	4.1667%
2	2	0	0	0	0	0	0	2	0	0	P	1	0.95	5.0000%
0	5	0	0	0	0	0	0	0	0	0	P	1.1	1.1	0.0000%
-5	7	0	6	5	6	-7	8	0	0	7	P	1	1.05	5.0000%
-5	0	9	0	0	0	0	5	0	0	0	P	0.85	0.8	5.8824%
0	0	0	0	0	0	0	0	0	5	8	P	0.95	0.95	0.0000%
7	5	3	0	0	8	-8	0	5	0	0	P	0.85	0.85	0.0000%
-2	-1	7	0	1	0	-4	3	3	1	7	P	1	1	0.0000%
1	3	0	7	0	1	0	0	2	0	0	P	1.15	1.15	0.0000%
0	0	0	2	1	0	3	2	2	0	3	P	1	1.05	5.0000%
0	0	2	0	1	1	5	2	5	7	9	P	0.95	0.95	0.0000%
2	5	0	3	5	-3	-3	0	2	0	2	P	1.1	1.1	0.0000%
0	3	0	2	0	-4	-3	4	3	0	7	P	1.6	1.6	0.0000%
0	9	0	6	0	-4	-7	7	9	0	0	P	1.2	1.2	0.0000%
-1	-2	2	5	7	-5	-4	5	6	5	7	P	1.2	1.2	0.0000%
-5	7	5	7	5	5	-4	0	0	0	2	P	1.25	1.2	4.0000%
-5	0	4	0	0	0	0	8	0	5	8	P	1.4	1.4	0.0000%
0	4	0	5	0	0	-2	0	0	0	5	P	0.95	0.95	0.0000%
1	4	2	0	0	8	2	8	8	0	8	P	0.8	0.8	0.0000%
-4	-2	2	4	2	-3	-5	5	4	0	4	P	1.1	1.1	0.0000%
-5	-5	9	0	0	2	-5	0	6	8	9	P	0.95	0.95	0.0000%
-9	9	5	5	0	0	0	0	0	0	6	P	1.9	1.9	0.0000%
-7	-5	0	3	0	-4	-3	0	4	3	0	P	1.1	1.1	0.0000%
2	2	0	3	0	3	-6	5	1	1	1	P	1.2	1.25	4.1667%
0	5	0	2	0	0	0	5	0	5	3	P	1	1	0.0000%

## ANEXOS- Resultados Experimentais

x_0	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_10	Set	y	y'	Erro Abs(%)
-5	0	0	5	7	-5	-5	0	5	0	0	P	0.9	0.9	0.0000%
1	2	0	2	2	-2	2	2	3	0	0	P	1.05	1.05	0.0000%
-6	-9	0	0	0	0	0	0	0	0	0	P	1.2	1.2	0.0000%
5	5	0	5	0	-5	-5	5	5	5	9	P	1.1	1.1	0.0000%
3	4	0	4	3	5	-4	3	5	5	3	P	1.1	1.05	4.5455%
6	5	0	0	0	7	0	7	0	6	0	P	0.8	0.8	0.0000%
-4	0	1	0	0	-5	-1	3	3	0	3	P	1	1	0.0000%
0	0	0	7	0	0	-6	7	7	0	0	P	1.05	1.1	4.7619%
-4	7	0	7	0	4	0	0	3	3	4	P	1.3	1.4	7.6923%
0	3	0	1	0	0	-1	0	2	0	0	P	0.95	0.95	0.0000%
0	4	0	0	0	2	0	0	0	0	0	P	1.4	1.4	0.0000%
0	6	0	6	6	-7	-4	3	5	1	6	P	1.25	1.2	4.0000%
0	0	7	0	0	-6	-6	5	3	0	7	P	1.1	1.05	4.5455%
4	8	0	5	9	-4	-5	4	5	0	5	P	0.75	0.75	0.0000%
-1	-1	0	0	0	-7	0	1	7	0	4	P	1	0.95	5.0000%

Tabela A-53: Árvore de Decisão R - Resultados Modelo Estratégico ME13TI4ADR

### Modelo Estratégico 2014 – Conjunto Teste 2015

x_0	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_10	Set	y	y'	Erro Abs(%)
-1	0	0	4	0	-6	-7	0	0	4	5	T	0.85	1.5	76.4706%
-1	0	0	8	8	-7	-6	0	0	6	7	T	1	0.95	5.0000%
-5	7	0	8	7	8	-8	8	0	0	8	T	1.05	1.1	4.7619%
0	6	0	9	0	0	0	0	0	0	0	T	1.05	1	4.7619%
0	5	3	7	0	-3	-5	0	6	4	6	T	1.15	1.2	4.3478%
-6	0	0	5	0	5	0	0	6	0	7	T	0.9	1.05	16.6667%
-7	0	0	0	0	0	-1	5	0	0	0	T	0.95	1.1	15.7895%
-3	5	3	1	3	3	3	3	3	4	0	T	0.9	0.9	0.0000%
0	9	0	9	5	9	-9	0	6	0	8	T	1.15	1.3	13.0435%
7	-5	5	0	7	0	-5	0	7	0	0	T	0.75	0.9	20.0000%
0	0	7	7	6	0	-8	7	8	6	7	T	1.15	1.15	0.0000%
-6	-5	0	6	0	0	0	7	0	6	5	T	1.1	0.95	13.6364%
-3	0	0	3	4	0	-4	3	0	0	0	T	1	0.95	5.0000%
0	4	3	5	0	0	-1	0	0	0	4	T	1.7	1.3	23.5294%
2	2	0	2	6	3	-4	0	0	4	3	T	1	1.75	75.0000%
2	5	0	3	3	-6	-7	0	4	0	0	T	0.95	1.1	15.7895%
-3	-3	2	4	9	-4	-7	7	4	4	7	T	1.05	1.15	9.5238%
6	7	0	5	4	5	-6	6	2	6	3	T	1.45	1.25	13.7931%
-8	0	0	8	5	0	-4	6	7	7	8	T	0.95	1.05	10.5263%
-1	-1	2	5	2	-5	-7	0	8	3	6	T	1	0.9	10.0000%
-2	6	0	8	0	7	-7	7	8	0	0	T	1.15	1	13.0435%
0	5	4	0	6	-9	-9	9	0	0	0	T	1.05	1.4	33.3333%
0	9	0	6	0	-4	-7	7	9	0	0	T	0.75	1	33.3333%
3	5	0	5	6	-7	-5	0	3	7	7	T	1.05	1.5	42.8571%
0	-5	5	6	0	5	0	5	0	0	7	T	0.8	1.3	62.5000%
0	2	0	2	0	3	3	0	2	0	0	T	1	1	0.0000%
-5	2	2	4	0	6	-5	5	4	7	8	T	1.2	1.05	12.5000%
0	5	0	4	4	-7	0	5	0	0	0	T	1.1	1.1	0.0000%
5	8	1	8	5	8	0	9	9	4	4	T	1.3	1.3	0.0000%
0	0	4	7	0	-5	-8	3	4	3	4	T	0.95	1.35	42.1053%
-2	0	0	0	0	9	-7	2	5	2	8	T	1.2	1	16.6667%
8	8	0	8	0	0	0	5	2	0	0	T	1.25	1.1	12.0000%

# ANEXOS- Resultados Experimentais

x_0	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_10	Set	y	y'	Erro Abs(%)
0	8	0	8	0	8	-7	3	6	5	7	T	1	1.3	30.0000%
0	0	0	0	0	-7	0	0	8	0	0	T	1.15	1.1	4.3478%
-4	9	0	8	0	-9	-1	0	0	0	2	T	1.15	1.2	4.3478%
5	5	0	0	0	9	-9	6	9	0	9	T	0.6	1.3	116.6667%
-4	5	0	0	0	5	0	8	5	0	5	T	1.15	1.15	0.0000%
-4	-7	9	9	0	-6	6	2	7	2	3	T	1.1	1.05	4.5455%
0	6	0	6	0	6	0	6	8	0	0	T	1.05	1	4.7619%
1	1	0	7	0	0	-2	2	0	0	2	T	0.9	1.2	33.3333%
-9	-8	1	8	5	0	0	7	0	8	7	T	1.25	1.05	16.0000%
-5	0	0	3	4	-4	-8	0	0	4	9	T	1	1.05	5.0000%
0	0	0	0	0	0	0	0	9	9	9	T	1.1	1.05	4.5455%
0	7	0	8	6	-6	-7	0	4	5	6	T	1	1.1	10.0000%
-7	0	7	2	4	2	6	5	6	3	7	T	1.7	0.9	47.0588%
5	0	5	0	0	-5	-5	6	6	5	5	T	1.05	0.8	23.8095%
5	5	0	8	0	6	0	5	4	0	5	T	1.15	0.75	34.7826%
-5	-5	5	5	5	5	5	5	5	0	5	T	1	1	0.0000%
4	9	0	8	0	0	0	0	9	0	0	T	1.4	0.85	39.2857%
2	-2	0	0	1	2	2	3	2	0	4	T	0.95	1.05	10.5263%
2	3	0	0	4	-4	0	0	3	0	2	T	1	1.05	5.0000%
0	0	1	2	5	7	-7	0	7	1	1	T	0.95	0.9	5.2632%
-6	3	0	2	0	2	-4	0	0	1	2	T	1.15	0.95	17.3913%
5	-5	0	6	0	6	8	0	9	0	9	T	1.05	1.75	66.6667%
-6	0	4	4	4	6	-6	7	3	3	6	T	1	1	0.0000%
-7	7	1	0	3	8	-8	8	5	5	7	T	1.15	1	13.0435%
-5	7	5	7	6	-6	-6	6	7	6	1	T	1	1.15	15.0000%
-6	-2	0	8	0	-8	-9	8	7	8	0	T	0.85	0.95	11.7647%
-6	-5	0	5	0	-4	-3	0	4	5	0	T	0.95	1.05	10.5263%
2	6	0	9	0	7	-6	5	1	9	7	T	0.9	1.25	38.8889%
0	7	2	6	0	-7	-6	5	6	6	0	T	1.15	1	13.0435%
1	4	0	3	0	-5	-8	0	7	8	7	T	1	0.85	15.0000%
6	5	0	6	0	-6	-6	0	7	5	7	T	1.15	0.85	26.0870%
0	9	0	4	0	-1	-3	0	0	0	0	T	0.95	1	5.2632%
0	0	0	6	0	0	0	0	2	0	6	T	1.35	1.3	3.7037%
3	7	0	8	0	-8	0	7	3	9	5	T	1.05	1.2	14.2857%
-1	0	0	4	9	-9	-8	9	8	9	5	T	1.05	0.95	9.5238%
0	8	0	2	0	-8	-3	4	6	8	4	T	1	1.2	20.0000%
-3	6	0	0	7	6	-6	2	5	0	0	T	0.9	1.3	44.4444%
0	0	0	3	0	-2	-3	6	3	2	4	T	1.1	1.2	9.0909%
-3	6	1	4	0	7	0	0	0	6	7	T	1.05	1.05	0.0000%
-4	4	0	4	5	4	-5	0	0	5	5	T	1.3	0.95	26.9231%
-5	0	0	6	8	-5	-7	0	5	0	0	T	1.3	1.05	19.2308%
-7	8	0	8	0	9	0	0	7	7	7	T	1.05	1.2	14.2857%
0	0	0	7	0	-7	-8	7	7	7	0	T	1.25	1.35	8.0000%
-7	-7	0	0	0	0	0	0	0	0	0	T	1.1	1.2	9.0909%
5	5	0	5	0	-5	-5	5	5	5	9	T	1.2	1.15	4.1667%
3	6	2	5	8	-8	-8	0	4	3	6	T	1.2	0.95	20.8333%
3	4	0	4	3	5	-4	3	5	5	4	T	1	1.3	30.0000%
5	5	0	5	5	5	-5	0	5	6	9	T	1.25	1	20.0000%
8	5	0	0	0	7	0	7	0	8	0	T	1.2	1	16.6667%
5	7	0	4	0	-6	0	5	4	0	0	T	1	0.75	25.0000%
2	0	4	0	0	-6	-1	6	7	0	6	T	0.9	0.8	11.1111%
0	5	0	5	0	5	0	0	0	0	3	T	1.3	1.3	0.0000%
-5	5	0	4	0	9	-7	4	7	7	0	T	1.05	1	4.7619%
0	0	0	7	0	0	-6	7	8	0	0	T	1.15	1	13.0435%
-5	7	0	0	4	6	-7	7	7	0	0	T	1.3	1.25	3.8462%
-3	0	0	4	0	0	-4	3	5	0	0	T	1.15	1	13.0435%

# ANEXOS- Resultados Experimentais

x_0	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_10	Set	y	y'	Erro Abs(%)
-6	6	5	7	0	0	-7	3	4	7	7	T	1.3	1.2	7.6923%
-7	7	0	5	0	0	-8	0	8	0	6	T	1.05	0.95	9.5238%
0	4	0	5	0	-5	-6	5	6	6	5	T	1.6	0.9	43.7500%
1	4	0	8	0	7	-6	4	6	1	6	T	0.75	1.15	53.3333%
5	6	0	6	0	6	-5	2	4	0	4	T	1.15	0.75	34.7826%
3	0	0	5	3	-5	-6	7	6	6	6	T	1.4	1.15	17.8571%
1	1	0	8	0	7	0	5	7	0	0	T	1.15	1.15	0.0000%
0	8	0	7	8	-8	-8	6	7	2	7	T	1.3	1.1	15.3846%
0	0	7	0	0	-6	-8	9	7	0	9	T	1.15	0.95	17.3913%
0	5	0	8	2	7	-7	8	4	7	5	T	1.2	0.55	54.1667%
0	5	0	2	0	0	0	0	3	3	0	T	1.05	1	4.7619%
0	0	0	2	0	-3	0	2	4	0	3	T	1.35	1.05	22.2222%
8	7	0	0	9	2	-9	0	7	5	9	T	1.15	0.9	21.7391%
0	0	0	0	0	0	-5	1	8	8	8	T	1.1	1.05	4.5455%
-5	5	0	7	0	-9	-7	7	3	6	8	T	1.9	1.2	36.8421%
0	8	0	0	0	7	-9	8	0	8	9	T	1.2	1	16.6667%
4	8	0	2	0	-6	-7	0	3	0	5	T	1.75	1.25	28.5714%
7	7	0	7	0	7	0	7	0	0	0	T	1	1.7	70.0000%
0	5	0	0	0	5	-5	5	0	5	0	T	1.2	1	16.6667%
-5	0	0	0	0	0	-9	8	0	8	0	T	0.65	1.1	69.2308%
5	9	0	8	0	6	0	0	0	9	0	T	1.05	1.1	4.7619%
5	9	0	0	0	9	-5	5	9	3	0	T	1.1	1.05	4.5455%
6	9	0	6	5	-9	9	4	0	5	6	T	1.2	1.75	45.8333%
3	9	0	2	0	9	-3	9	5	0	5	T	1.15	1.15	0.0000%
5	9	0	5	0	-5	-9	0	0	5	5	T	1.9	1.25	34.2105%
0	-3	0	0	0	0	-3	0	0	0	4	T	0.95	0.9	5.2632%
0	0	0	0	0	9	-9	9	9	0	0	T	1.25	1.1	12.0000%
7	6	0	5	0	8	-5	5	0	0	0	T	1.25	1.4	12.0000%
-1	-1	0	0	0	-7	0	1	7	0	4	T	1	1.05	5.0000%
5	8	0	0	0	5	-5	0	0	0	0	T	0.95	1.25	31.5789%
3	7	0	5	0	3	0	0	0	0	0	T	1.8	1.2	33.3333%
-2	-1	7	0	1	0	-5	5	5	5	7	T	1.35	0.8	40.7407%
-5	0	1	5	0	-9	-5	7	0	5	9	T	0.9	1.5	66.6667%
7	7	0	6	0	0	-6	0	0	0	6	T	1.5	1.25	16.6667%
-6	6	3	4	0	3	0	4	4	0	0	T	1.05	1	4.7619%
-7	8	5	5	7	7	-7	0	0	6	6	T	1	1	0.0000%
-8	6	3	8	5	0	-8	5	3	7	5	T	0.95	1.15	21.0526%
-2	7	0	4	0	-6	-4	0	0	2	4	T	1.05	1.2	14.2857%
0	0	0	5	4	-3	-1	0	2	0	0	T	1.2	0.95	20.8333%
-1	6	0	2	9	-9	-4	6	6	4	2	T	1.65	0.9	45.4545%
0	0	0	5	0	-7	0	8	7	0	8	T	1	1.05	5.0000%
0	0	0	0	0	-7	3	4	1	0	0	T	1.25	1.1	12.0000%
-6	-1	9	2	0	8	-6	0	0	8	9	T	0.75	0.75	0.0000%
0	9	0	8	0	6	-8	7	5	7	6	T	1.35	1.3	3.7037%
0	0	6	0	8	6	-5	8	6	6	5	T	0.65	1.05	61.5385%
6	7	0	0	0	-8	0	8	6	0	0	T	1.1	1.05	4.5455%
0	0	0	5	5	-5	0	0	0	5	9	T	1	0.95	5.0000%
3	5	0	1	3	6	-4	1	0	0	2	T	0.8	1.75	118.75%
-3	0	0	0	0	2	0	2	6	0	0	T	1.1	1.1	0.0000%
0	-6	0	0	0	0	-5	0	0	0	4	T	1.25	0.9	28.0000%
1	-2	0	5	3	-3	-3	1	0	5	3	T	1	1.05	5.0000%
4	6	4	6	5	8	-6	0	2	0	2	T	1.1	1.25	13.6364%
8	8	0	7	0	8	7	7	5	0	5	T	1.05	1.1	4.7619%
7	7	0	6	0	-6	-6	6	6	6	6	T	1.15	1.95	69.5652%
0	0	5	3	0	-6	3	0	6	3	4	T	1.1	1.05	4.5455%
1	6	0	1	0	7	-8	2	8	0	6	T	1.25	1.15	8.0000%



# ANEXOS- Resultados Experimentais

x_0	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_10	Set	y	y'	Erro Abs(%)
0	8	0	0	0	7	-7	0	8	0	0	T	0.8	1.05	31.2500%
5	7	0	5	4	-4	0	8	8	5	7	T	1.1	1	9.0909%
-5	6	2	7	1	-7	0	0	6	7	7	T	1	1.2	20.0000%
2	2	0	4	0	5	3	5	8	6	0	T	1.05	1.15	9.5238%
5	8	0	5	0	0	0	0	0	0	5	T	1.5	1.1	26.6667%
-3	-5	2	3	3	-5	-5	5	5	1	3	T	0.9	1.3	44.4444%
-2	0	0	2	0	6	-3	0	0	0	0	T	1.15	1	13.0435%
0	7	6	0	5	-5	-5	3	0	3	6	T	1.05	1.25	19.0476%
5	5	0	0	4	7	-5	4	2	0	4	T	1.6	1.3	18.7500%
6	7	0	3	0	7	0	0	7	2	8	T	0.95	1	5.2632%
4	5	7	7	5	5	-5	2	2	6	3	T	1	1.5	50.0000%
-3	3	0	1	0	-5	-4	0	4	3	4	T	1.05	1.05	0.0000%
-5	9	0	7	0	0	-9	0	9	0	9	T	1.25	1.3	4.0000%
6	7	0	3	0	-7	-7	6	2	0	0	T	1.05	1.25	19.0476%
-4	0	0	7	0	-7	-8	7	6	4	7	T	1.15	1.35	17.3913%
5	5	0	0	0	0	-4	3	0	0	0	T	1.1	0.9	18.1818%
6	7	0	8	0	7	-9	0	7	7	7	T	1.35	1	25.9259%
9	0	5	6	8	-6	-8	1	7	0	9	T	1.1	1.95	77.2727%
-7	6	0	1	3	4	-6	7	5	0	5	T	1.3	0.9	30.7692%
2	3	0	3	0	5	-4	0	4	0	0	T	1.55	1.1	29.0323%
0	7	0	4	0	6	0	3	0	0	0	T	1.8	1	44.4444%
4	4	0	1	0	7	0	0	3	0	0	T	0.95	1.7	78.9474%
2	6	7	0	0	2	-3	0	0	0	0	P	0.95	0.9	5.2632%
-1	0	0	6	8	-7	-6	0	0	5	7	P	0.9	0.95	5.5556%
0	6	0	6	9	0	0	0	0	0	0	P	1.15	1.1	4.3478%
5	9	0	6	6	0	0	4	5	4	7	P	1	1	0.0000%
-5	0	2	0	0	0	-1	5	0	0	0	P	1.05	1.1	4.7619%
0	0	0	0	0	0	0	0	0	4	8	P	0.95	0.9	5.2632%
0	9	0	9	5	9	-9	0	6	0	8	P	1.25	1.3	4.0000%
7	8	3	0	0	8	-8	7	5	0	0	P	1.2	1.25	4.1667%
-6	-5	0	6	0	0	0	7	0	6	5	P	0.95	0.95	0.0000%
1	4	0	8	0	1	-3	0	4	0	0	P	1.1	1.1	0.0000%
2	3	0	2	9	4	-3	4	0	0	4	P	1.2	1.2	0.0000%
0	4	3	5	0	0	-1	0	0	0	2	P	1.35	1.3	3.7037%
0	2	0	0	6	3	-2	0	0	1	3	P	1.05	1.05	0.0000%
1	1	3	0	2	3	3	4	2	6	6	P	0.65	0.6	7.6923%
2	5	0	3	4	-4	-6	0	5	0	0	P	0.85	0.85	0.0000%
0	7	0	7	0	-8	-6	0	6	7	8	P	1.25	1.2	4.0000%
-3	-3	2	3	9	-3	-7	7	4	4	7	P	1.1	1.15	4.5455%
0	3	0	2	0	-4	-4	4	3	0	8	P	1.4	1.4	0.0000%
6	7	0	5	4	5	-6	6	2	6	3	P	1.2	1.25	4.1667%
-6	6	6	4	5	0	-7	5	3	5	5	P	1.1	1.15	4.5455%
-8	7	0	0	0	6	-2	2	7	0	0	P	1.25	1.25	0.0000%
0	0	0	5	0	-2	-1	0	1	0	0	P	0.85	0.85	0.0000%
-2	-1	2	4	2	-5	-7	0	3	3	6	P	0.95	0.9	5.2632%
-2	6	0	3	0	6	-8	7	7	0	0	P	1	1	0.0000%
0	5	4	0	6	-9	-9	9	0	0	0	P	1.25	1.4	12.0000%
0	9	0	6	0	-4	-7	7	9	0	0	P	1	1	0.0000%
-1	-2	2	5	7	-5	-4	5	6	5	7	P	1.15	1.15	0.0000%
0	2	0	2	0	3	3	0	0	0	0	P	1	1	0.0000%
-4	1	1	2	0	4	-4	3	4	4	5	P	0.9	0.95	5.5556%
-4	0	0	6	0	-7	0	8	7	0	8	P	1.05	1.05	0.0000%
0	5	0	4	3	-5	0	5	0	0	0	P	1.05	1.1	4.7619%
4	7	1	7	4	7	0	8	8	4	4	P	1.3	1.3	0.0000%
-6	-1	9	2	0	-6	-6	0	0	8	9	P	1.15	1.15	0.0000%
0	5	0	5	0	-6	0	5	5	0	5	P	1.2	1.2	0.0000%

# ANEXOS- Resultados Experimentais

x_0	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_10	Set	y	y'	Erro Abs(%)
-2	0	0	0	7	9	-7	2	6	2	8	P	1.05	1	4.7619%
-6	0	0	0	0	6	-5	0	6	0	6	P	0.6	0.6	0.0000%
-2	-4	6	0	0	0	-4	2	0	0	6	P	0.6	0.6	0.0000%
0	8	0	8	6	-6	-5	7	0	0	8	P	1.05	1.1	4.7619%
3	7	0	0	0	-8	0	8	6	0	0	P	1.05	1.05	0.0000%
0	7	0	2	2	-5	-3	0	3	7	0	P	0.85	0.9	5.8824%
-4	9	0	8	0	-9	-1	0	0	0	2	P	1.25	1.2	4.0000%
6	6	0	0	0	6	0	6	8	0	0	P	1.15	1.15	0.0000%
0	0	4	0	9	0	1	1	0	0	0	P	0.9	0.9	0.0000%
0	0	0	5	5	-5	0	0	0	5	9	P	0.95	0.95	0.0000%
-3	8	0	2	0	0	-6	0	0	0	7	P	1.2	1.2	0.0000%
1	4	2	0	0	8	2	8	8	0	8	P	1.1	1.15	4.5455%
0	7	0	0	6	-6	-7	0	4	0	6	P	1.25	1.25	0.0000%
-8	0	6	1	2	1	4	2	3	2	4	P	1.2	1.2	0.0000%
-5	-5	5	5	5	5	5	5	5	5	5	P	1	1	0.0000%
2	4	0	0	0	6	-4	1	0	0	2	P	1.3	1.3	0.0000%
0	8	0	5	0	0	-9	0	9	3	0	P	0.95	0.95	0.0000%
1	3	0	0	2	2	3	3	3	0	4	P	1	1.05	5.0000%
4	-5	5	6	6	5	0	5	6	6	6	P	1.75	1.75	0.0000%
0	-5	6	0	0	4	-6	0	7	6	6	P	1	0.95	5.0000%
-6	3	0	2	0	2	-4	0	0	1	2	P	0.95	0.95	0.0000%
0	7	1	3	6	-5	7	3	4	3	1	P	0.95	0.95	0.0000%
1	-1	0	1	0	0	-2	1	0	0	2	P	1.05	1.05	0.0000%
-7	9	8	9	0	0	0	0	0	0	6	P	0.75	0.75	0.0000%
-2	-2	2	6	9	-7	-8	3	5	7	4	P	1.15	1.15	0.0000%
-5	-3	5	0	6	-5	-5	6	7	7	2	P	0.9	0.9	0.0000%
4	7	0	0	0	0	0	4	0	0	0	P	1.25	1.25	0.0000%
7	6	0	5	0	-5	-5	5	5	5	5	P	1.95	1.95	0.0000%
-7	-5	0	4	0	-4	-3	0	4	4	0	P	1.05	1.05	0.0000%
1	5	0	1	0	7	-8	2	8	0	4	P	1.2	1.15	4.1667%
5	4	0	5	0	-6	-5	0	2	0	4	P	1.4	1.4	0.0000%
0	0	3	0	0	0	-3	0	3	2	0	P	0.85	0.8	5.8824%
6	5	1	5	0	6	0	0	5	0	6	P	1.5	1.5	0.0000%
0	8	0	0	0	7	-7	0	8	0	0	P	1	1.05	5.0000%
3	6	0	8	0	-4	0	7	8	7	4	P	1.05	1	4.7619%
0	0	0	0	0	-5	0	0	0	4	4	P	0.5	0.5	0.0000%
5	8	0	4	0	-8	-1	8	6	7	4	P	1	0.95	5.0000%
-2	5	0	0	8	6	-3	7	5	0	0	P	1.15	1.15	0.0000%
-4	4	0	4	4	3	-4	0	0	4	4	P	0.95	0.95	0.0000%
0	0	0	6	0	-6	-7	6	6	6	0	P	1.1	1.05	4.5455%
-5	3	3	5	3	-5	0	0	5	5	6	P	1.3	1.3	0.0000%
5	5	0	5	0	-5	-5	5	5	5	9	P	1.15	1.15	0.0000%
-6	5	0	5	0	-3	-4	3	3	2	5	P	1.15	1.2	4.3478%
7	6	0	4	0	6	3	5	8	5	0	P	1.15	1.1	4.3478%
3	4	0	4	3	5	-4	3	5	5	4	P	1.3	1.3	0.0000%
0	7	3	0	5	-5	-5	3	2	2	4	P	1.2	1.25	4.1667%
0	5	0	5	0	5	0	0	5	0	3	P	1.25	1.3	4.0000%
5	7	0	0	1	5	-7	8	8	2	0	P	1.1	1.05	4.5455%
1	2	0	2	3	-3	-3	3	0	1	2	P	1.25	1.2	4.0000%
4	6	0	2	0	6	0	0	4	0	6	P	1.05	1.1	4.7619%
-7	7	0	4	0	0	-8	0	8	0	6	P	0.95	0.95	0.0000%
-9	9	0	5	0	-9	-9	0	5	0	0	P	1.35	1.3	3.7037%
-3	3	0	1	0	0	-3	0	3	1	2	P	1.15	1.2	4.3478%
3	5	0	0	0	2	-9	7	9	5	9	P	1.05	1	4.7619%
5	3	6	5	5	5	0	6	6	6	7	P	1	1	0.0000%
0	4	0	4	0	7	-2	0	3	0	0	P	1	1	0.0000%

# ANEXOS- Resultados Experimentais

x_0	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_10	Set	y	y'	Erro Abs(%)
5	6	0	6	0	6	-5	2	4	0	4	P	0.8	0.75	6.2500%
-3	0	0	3	0	-6	-6	5	2	2	6	P	1.4	1.4	0.0000%
-7	0	2	4	0	0	0	9	2	7	9	P	1.05	1.05	0.0000%
-5	4	0	2	0	0	0	0	3	2	0	P	0.95	1	5.2632%
-3	6	0	6	5	-4	8	0	0	6	0	P	1.15	1.1	4.3478%
1	5	0	1	0	-2	0	0	0	0	0	P	1.25	1.2	4.0000%
0	9	3	9	0	-5	9	0	5	8	6	P	1.75	1.75	0.0000%
0	0	0	0	0	1	0	0	0	0	8	P	0.9	0.9	0.0000%
6	5	0	9	0	6	-4	6	4	0	4	P	0.7	0.75	7.1429%
0	0	0	9	0	-9	-9	5	9	0	5	P	1.35	1.3	3.7037%
0	8	0	3	9	-5	-5	3	5	0	5	P	1.1	1.1	0.0000%
0	9	0	0	0	9	-3	9	5	0	2	P	1.5	1.4	6.6667%
0	0	8	9	0	-9	-9	5	5	0	0	P	1.75	1.75	0.0000%
-4	4	0	0	0	0	-3	0	4	4	4	P	1.15	1.15	0.0000%
-1	-1	0	0	0	-7	0	1	7	0	4	P	1.1	1.05	4.5455%
-6	0	0	5	0	5	0	0	6	0	7	P	1.05	1.05	0.0000%
-2	-1	7	0	1	0	-4	4	3	1	7	P	0.85	0.8	5.8824%
-5	-1	5	4	2	-6	-4	3	2	4	6	P	0.55	0.55	0.0000%
1	4	0	3	0	0	0	3	6	0	0	P	1.15	1.15	0.0000%
0	4	0	2	0	-5	-4	0	0	2	3	P	0.95	0.9	5.2632%
-5	7	5	7	5	6	-5	3	0	4	5	P	1	1	0.0000%
-6	6	0	0	8	0	-2	4	0	0	3	P	0.9	0.9	0.0000%
5	4	0	0	0	0	-1	6	6	0	5	P	0.85	0.9	5.8824%
6	0	5	0	0	-5	-6	6	0	0	5	P	0.9	0.95	5.5556%
-7	-2	6	0	0	-4	0	0	6	7	9	P	0.75	0.8	6.6667%
-7	0	8	7	7	0	0	0	0	0	3	P	1.15	1.15	0.0000%
-3	0	0	2	7	3	-5	5	4	5	6	P	1.1	1.05	4.5455%
2	4	0	5	0	5	-5	5	1	4	2	P	1.5	1.5	0.0000%
0	7	2	6	0	-7	-6	5	5	0	0	P	1.05	1	4.7619%
0	0	0	4	0	0	0	0	2	0	5	P	1.1	1.05	4.5455%
3	1	0	4	0	-4	-3	4	3	0	0	P	1.2	1.2	0.0000%
0	0	0	2	0	-1	-3	4	2	0	1	P	1.25	1.2	4.0000%
1	2	0	4	3	-3	-6	4	4	5	0	P	1.1	1.1	0.0000%
-6	3	8	1	6	0	-2	1	3	7	7	P	1	1.05	5.0000%
0	0	0	0	5	0	0	0	5	6	9	P	1.05	1.05	0.0000%
-6	-3	0	0	0	0	0	0	0	0	0	P	1.3	1.2	7.6923%
0	0	0	7	0	0	-6	7	6	0	0	P	1	1	0.0000%
-6	0	5	7	0	0	-7	3	4	4	7	P	1.25	1.2	4.0000%
1	3	0	7	0	6	-5	4	6	2	5	P	1.1	1.15	4.5455%
-4	0	0	4	1	-3	-4	4	2	1	4	P	1.5	1.5	0.0000%
0	0	0	5	0	-6	-7	7	5	0	9	P	1.2	1.2	0.0000%
5	6	0	1	0	0	4	0	0	0	0	P	1.35	1.35	0.0000%
0	5	9	0	0	5	-5	5	0	5	0	P	1	1	0.0000%
4	5	0	5	2	7	-7	8	3	5	7	P	1.3	1.25	3.8462%
-1	-3	0	4	0	-6	-6	0	0	4	5	P	1.55	1.5	3.2258%
-3	4	3	1	3	3	3	3	3	3	0	P	0.85	0.9	5.8824%
-2	0	0	0	3	0	-6	6	0	0	0	P	1.2	1.2	0.0000%
-2	0	0	0	0	0	-1	0	3	0	4	P	0.95	1	5.2632%
8	8	0	5	6	4	-5	7	4	0	0	P	1.1	1.1	0.0000%
-8	0	5	5	0	0	-4	6	7	7	8	P	1	1.05	5.0000%
-1	6	0	2	9	-9	-4	5	6	4	2	P	0.95	0.9	5.2632%
0	0	0	0	0	-5	2	3	1	0	0	P	1.05	1.1	4.7619%
0	0	4	7	0	-5	-8	3	4	3	4	P	1.35	1.35	0.0000%
5	6	0	7	0	0	0	5	2	0	7	P	1.1	1.1	0.0000%
5	5	0	5	0	4	-2	8	5	0	5	P	1.15	1.15	0.0000%
0	0	0	0	0	0	0	0	0	4	9	P	1.15	1.15	0.0000%

## ANEXOS- Resultados Experimentais

x_0	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_10	Set	y	y'	Erro Abs(%)
0	6	0	5	4	0	-5	0	7	0	5	P	1.05	1.1	4.7619%
2	3	0	0	4	-4	0	0	3	0	2	P	1	1.05	5.0000%
8	8	0	7	0	8	7	7	5	0	5	P	1.05	1.1	4.7619%
0	0	0	1	0	-5	-6	0	3	0	0	P	1.35	1.4	3.7037%
6	7	0	9	0	8	-9	0	7	0	7	P	1.05	1	4.7619%
0	4	0	4	0	-4	-7	0	5	7	6	P	0.9	0.9	0.0000%
5	5	0	4	3	-4	-4	5	2	0	5	P	1.75	1.75	0.0000%
0	0	0	2	9	-9	-8	9	8	0	5	P	0.95	0.9	5.2632%
4	7	0	2	2	-4	0	4	4	4	7	P	1.05	1.1	4.7619%
-5	0	0	5	8	-5	-7	0	5	0	0	P	1.05	1.05	0.0000%
0	-1	0	1	0	-1	-1	1	1	1	1	P	1	1.05	5.0000%
-4	-8	0	0	0	0	0	0	0	0	0	P	1.15	1.2	4.3478%
3	6	2	5	5	-8	-8	0	7	3	6	P	0.9	0.95	5.5556%
-1	1	1	0	7	-5	-3	0	7	8	8	P	1.1	1.05	4.5455%
-4	0	1	0	0	-6	-1	6	6	0	5	P	1	1	0.0000%
5	5	0	0	0	7	-5	4	6	6	0	P	0.9	0.9	0.0000%
-9	-3	7	3	7	-5	-6	0	4	0	4	P	1.15	1.15	0.0000%
-8	0	0	0	0	0	0	0	0	0	0	P	1.15	1.1	4.3478%
0	0	8	0	7	0	-6	6	0	5	7	P	1.05	1.05	0.0000%
1	7	0	6	1	-8	-7	4	8	3	8	P	0.75	0.75	0.0000%
-5	9	0	6	0	0	-8	0	8	0	9	P	1.15	1.2	4.3478%
-4	-8	0	0	0	-8	-5	7	9	0	8	P	0.95	1	5.2632%
1	1	0	7	0	7	0	0	0	0	0	P	1.7	1.7	0.0000%
0	5	0	8	6	7	-7	8	6	3	5	P	1.05	1.1	4.7619%
0	0	0	0	0	0	-5	1	1	8	8	P	1.05	1.05	0.0000%
1	5	0	5	0	7	-7	0	5	4	6	P	1.1	1.15	4.5455%
7	7	0	7	0	-7	0	0	0	0	0	P	1.15	1.1	4.3478%
-5	0	5	0	5	9	0	5	7	5	5	P	1.05	1.05	0.0000%
4	9	0	8	0	6	0	0	0	9	0	P	1.2	1.2	0.0000%
0	0	5	1	0	7	0	7	7	0	9	P	1.1	1.05	4.5455%
5	9	0	0	0	9	-5	5	9	9	0	P	1	1	0.0000%
5	6	0	5	0	5	-5	5	0	0	0	P	1.35	1.4	3.7037%

Tabela A-54: Árvore de Decisão R - Resultados Modelo Estratégico ME14T15ADR

### Modelo Estratégico Global

Modelo	Amostra	Set	y	y'	Erro Abs(%)
MEGlobalADR	1	test	0.9	1	11.1111%
MEGlobalADR	2	test	1.1	1.15	4.5455%
MEGlobalADR	3	test	1.05	0.7	33.3333%
MEGlobalADR	4	test	0.65	0.95	46.1538%
MEGlobalADR	5	test	1.4	1.6	14.2857%
MEGlobalADR	6	test	0.85	1.05	23.5294%
MEGlobalADR	7	test	1.25	0.75	40.0000%
MEGlobalADR	8	test	1.05	1.35	28.5714%
MEGlobalADR	9	test	1.15	0.6	47.8261%
MEGlobalADR	10	test	0.9	0.7	22.2222%
MEGlobalADR	11	test	1.2	1.15	4.1667%
MEGlobalADR	12	test	0.95	0.75	21.0526%
MEGlobalADR	13	test	1	0.75	25.0000%
MEGlobalADR	14	test	0.95	1.15	21.0526%
MEGlobalADR	15	test	1.05	1.1	4.7619%

## ANEXOS- Resultados Experimentais

Modelo	Amostra	Set	y	y'	Erro Abs(%)
MEGlobalADR	16	test	0.85	0.7	17.6471%
MEGlobalADR	17	test	0.5	0.95	90.0000%
MEGlobalADR	18	test	1	1.1	10.0000%
MEGlobalADR	19	test	1.15	1.15	0.0000%
MEGlobalADR	20	test	1.15	1.1	4.3478%
MEGlobalADR	21	test	1.15	1.6	39.1304%
MEGlobalADR	22	test	1.3	1.1	15.3846%
MEGlobalADR	23	test	1.1	1.1	0.0000%
MEGlobalADR	24	test	1.05	0.9	14.2857%
MEGlobalADR	25	test	1	1.8	80.0000%
MEGlobalADR	26	test	0.8	1.2	50.0000%
MEGlobalADR	27	test	1.4	1.05	25.0000%
MEGlobalADR	28	test	0.95	1.3	36.8421%
MEGlobalADR	29	test	1.15	1.75	52.1739%
MEGlobalADR	30	test	0.9	0.95	5.5556%
MEGlobalADR	31	test	1.35	1.8	33.3333%
MEGlobalADR	32	test	1.5	0.85	43.3333%
MEGlobalADR	33	test	1.15	1.35	17.3913%
MEGlobalADR	34	test	1.05	1.1	4.7619%
MEGlobalADR	35	test	0.95	1.6	68.4211%
MEGlobalADR	36	test	0.75	0.9	20.0000%
MEGlobalADR	37	test	1.5	0.9	40.0000%
MEGlobalADR	38	test	1.1	1.5	36.3636%
MEGlobalADR	39	test	1.3	1.15	11.5385%
MEGlobalADR	40	test	1	1.1	10.0000%
MEGlobalADR	41	test	1.1	0.75	31.8182%
MEGlobalADR	42	test	1.55	1	35.4839%
MEGlobalADR	43	test	1.1	1.1	0.0000%
MEGlobalADR	44	test	1.35	0.95	29.6296%
MEGlobalADR	45	test	1	1	0.0000%
MEGlobalADR	46	test	1.05	1.25	19.0476%
MEGlobalADR	47	test	1	0.9	10.0000%
MEGlobalADR	48	test	1.1	0.95	13.6364%
MEGlobalADR	49	test	1	0.95	5.0000%
MEGlobalADR	50	test	0.9	0.6	33.3333%
MEGlobalADR	51	test	1.1	1	9.0909%
MEGlobalADR	52	test	1	1.1	10.0000%
MEGlobalADR	53	test	1	1.15	15.0000%
MEGlobalADR	54	test	1.15	1.3	13.0435%
MEGlobalADR	55	test	1.05	0.95	9.5238%
MEGlobalADR	56	test	1.2	1.3	8.3333%
MEGlobalADR	57	test	1.85	1.25	32.4324%
MEGlobalADR	58	test	1.2	1.25	4.1667%
MEGlobalADR	59	test	1.2	1.2	0.0000%
MEGlobalADR	60	test	1.35	1.1	18.5185%
MEGlobalADR	61	test	1.05	0.65	38.0952%
MEGlobalADR	62	test	0.8	1.25	56.2500%
MEGlobalADR	63	test	0.95	1	5.2632%
MEGlobalADR	64	test	1.15	0.9	21.7391%
MEGlobalADR	65	test	1.1	1.2	9.0909%
MEGlobalADR	66	test	0.75	1.25	66.6667%
MEGlobalADR	67	test	1.05	0.75	28.5714%
MEGlobalADR	68	test	0.85	0.85	0.0000%

## ANEXOS- Resultados Experimentais

Modelo	Amostra	Set	y	y'	Erro Abs(%)
MEGlobalADR	69	test	0.85	1.1	29.4118%
MEGlobalADR	70	test	0.8	1.5	87.5000%
MEGlobalADR	71	test	0.9	1	11.1111%
MEGlobalADR	72	test	1	1.15	15.0000%
MEGlobalADR	73	test	0.6	1	66.6667%
MEGlobalADR	74	test	0.7	1.1	57.1429%
MEGlobalADR	75	test	0.8	1.8	125.0000%
MEGlobalADR	76	test	1.55	1.2	22.5806%
MEGlobalADR	77	test	1.1	0.95	13.6364%
MEGlobalADR	78	test	0.85	0.9	5.8824%
MEGlobalADR	79	test	0.95	0.95	0.0000%
MEGlobalADR	80	test	1	1.3	30.0000%
MEGlobalADR	81	test	1.1	1	9.0909%
MEGlobalADR	82	test	1.4	0.95	32.1429%
MEGlobalADR	83	test	0.95	1.35	42.1053%
MEGlobalADR	84	test	1.1	1.1	0.0000%
MEGlobalADR	85	test	1.2	0.9	25.0000%
MEGlobalADR	86	test	1.05	1.3	23.8095%
MEGlobalADR	87	test	1	0.7	30.0000%
MEGlobalADR	88	test	1.3	0.95	26.9231%
MEGlobalADR	89	test	0.9	1.1	22.2222%
MEGlobalADR	90	test	0.95	1.15	21.0526%
MEGlobalADR	91	test	0.75	0.75	0.0000%
MEGlobalADR	92	test	1.15	0.75	34.7826%
MEGlobalADR	93	test	1.7	1.35	20.5882%
MEGlobalADR	94	test	0.95	0.85	10.5263%
MEGlobalADR	95	test	1	0.75	25.0000%
MEGlobalADR	96	test	1.15	1	13.0435%
MEGlobalADR	97	test	1.05	0.75	28.5714%
MEGlobalADR	98	test	1	1.3	30.0000%
MEGlobalADR	99	test	1.1	1	9.0909%
MEGlobalADR	100	test	1.15	1.1	4.3478%
MEGlobalADR	101	test	1.05	1.8	71.4286%
MEGlobalADR	102	test	1.25	1.9	52.0000%
MEGlobalADR	103	test	1.7	1.15	32.3529%
MEGlobalADR	104	test	1.05	1.35	28.5714%
MEGlobalADR	105	test	1	0.95	5.0000%
MEGlobalADR	106	test	0.95	1	5.2632%
MEGlobalADR	107	test	1	1	0.0000%
MEGlobalADR	108	test	0.95	1.3	36.8421%
MEGlobalADR	109	test	1.15	1.15	0.0000%
MEGlobalADR	110	test	1.05	1.75	66.6667%
MEGlobalADR	111	test	1.15	1.2	4.3478%
MEGlobalADR	112	test	1	1	0.0000%
MEGlobalADR	113	test	0.85	1	17.6471%
MEGlobalADR	114	test	1	0.9	10.0000%
MEGlobalADR	115	test	0.95	1.05	10.5263%
MEGlobalADR	116	test	1.05	1.1	4.7619%
MEGlobalADR	117	test	1	0.9	10.0000%
MEGlobalADR	118	test	0.9	1.2	33.3333%
MEGlobalADR	119	test	1.05	0.9	14.2857%
MEGlobalADR	120	test	1.3	0.9	30.7692%
MEGlobalADR	121	test	1.3	1.05	19.2308%

## ANEXOS- Resultados Experimentais

Modelo	Amostra	Set	y	y'	Erro Abs(%)
MEGlobalADR	122	test	1.25	1.25	0.0000%
MEGlobalADR	123	test	1.1	1.15	4.5455%
MEGlobalADR	124	test	1.2	1.15	4.1667%
MEGlobalADR	125	test	1	1.1	10.0000%
MEGlobalADR	126	test	0.9	0.95	5.5556%
MEGlobalADR	127	test	1.3	1.35	3.8462%
MEGlobalADR	128	test	1.15	1.4	21.7391%
MEGlobalADR	129	test	1.15	1.05	8.6957%
MEGlobalADR	130	test	1	1.2	20.0000%
MEGlobalADR	131	test	1.2	1.1	8.3333%
MEGlobalADR	132	test	0.65	1.15	76.9231%
MEGlobalADR	133	test	1.05	1.2	14.2857%
MEGlobalADR	134	test	0.95	1.1	15.7895%
MEGlobalADR	135	test	1.25	1.4	12.0000%
MEGlobalADR	136	test	1.2	1	16.6667%
MEGlobalADR	137	test	1.25	1.05	16.0000%
MEGlobalADR	138	test	1.25	1.3	4.0000%
MEGlobalADR	139	test	0.9	0.95	5.5556%
MEGlobalADR	140	test	0.95	1.45	52.6316%
MEGlobalADR	141	test	1.55	1.15	25.8065%
MEGlobalADR	142	test	0.95	1.35	42.1053%
MEGlobalADR	1	train	1	1	0.0000%
MEGlobalADR	2	train	1.75	1.8	2.8571%
MEGlobalADR	3	train	1.05	1.05	0.0000%
MEGlobalADR	4	train	1.15	1.2	4.3478%
MEGlobalADR	5	train	1	1	0.0000%
MEGlobalADR	6	train	1.25	1.25	0.0000%
MEGlobalADR	7	train	1.65	1.3	21.2121%
MEGlobalADR	8	train	1	1	0.0000%
MEGlobalADR	9	train	1.15	1.15	0.0000%
MEGlobalADR	10	train	0.85	0.85	0.0000%
MEGlobalADR	11	train	1.45	1.3	10.3448%
MEGlobalADR	12	train	1	0.9	10.0000%
MEGlobalADR	13	train	1.05	1	4.7619%
MEGlobalADR	14	train	0.95	0.95	0.0000%
MEGlobalADR	15	train	0.9	0.9	0.0000%
MEGlobalADR	16	train	0.75	0.75	0.0000%
MEGlobalADR	17	train	1	1	0.0000%
MEGlobalADR	18	train	1.3	1.6	23.0769%
MEGlobalADR	19	train	1	1	0.0000%
MEGlobalADR	20	train	1.75	1.25	28.5714%
MEGlobalADR	21	train	1.2	1.2	0.0000%
MEGlobalADR	22	train	1.9	1.5	21.0526%
MEGlobalADR	23	train	1.1	1.1	0.0000%
MEGlobalADR	24	train	1	1	0.0000%
MEGlobalADR	25	train	1.25	1.25	0.0000%
MEGlobalADR	26	train	0.85	0.9	5.8824%
MEGlobalADR	27	train	0.55	0.8	45.4545%
MEGlobalADR	28	train	1.9	1.9	0.0000%
MEGlobalADR	29	train	1.5	1	33.3333%
MEGlobalADR	30	train	1.05	1	4.7619%
MEGlobalADR	31	train	1.25	1.2	4.0000%
MEGlobalADR	32	train	1.2	1.2	0.0000%

## ANEXOS- Resultados Experimentais

Modelo	Amostra	Set	y	y'	Erro Abs(%)
MEGlobalADR	33	train	1.15	1.15	0.0000%
MEGlobalADR	34	train	1.1	1.1	0.0000%
MEGlobalADR	35	train	1.6	1.6	0.0000%
MEGlobalADR	36	train	1.15	1.15	0.0000%
MEGlobalADR	37	train	1.2	1.15	4.1667%
MEGlobalADR	38	train	1.25	1.2	4.0000%
MEGlobalADR	39	train	1.2	1.2	0.0000%
MEGlobalADR	40	train	0.75	0.75	0.0000%
MEGlobalADR	41	train	1.25	1.25	0.0000%
MEGlobalADR	42	train	1.05	1.5	42.8571%
MEGlobalADR	43	train	0.9	0.9	0.0000%
MEGlobalADR	44	train	1.05	1.05	0.0000%
MEGlobalADR	45	train	1.15	1.1	4.3478%
MEGlobalADR	46	train	1.15	1.2	4.3478%
MEGlobalADR	47	train	1.15	1.1	4.3478%
MEGlobalADR	48	train	0.9	0.9	0.0000%
MEGlobalADR	49	train	1.2	1.2	0.0000%
MEGlobalADR	50	train	0.75	0.75	0.0000%
MEGlobalADR	51	train	1.15	1.1	4.3478%
MEGlobalADR	52	train	1.1	1.1	0.0000%
MEGlobalADR	53	train	1.1	0.95	13.6364%
MEGlobalADR	54	train	0.85	0.85	0.0000%
MEGlobalADR	55	train	0.6	0.75	25.0000%
MEGlobalADR	56	train	1.1	1.1	0.0000%
MEGlobalADR	57	train	0.9	0.9	0.0000%
MEGlobalADR	58	train	0.8	0.8	0.0000%
MEGlobalADR	59	train	1.15	1.15	0.0000%
MEGlobalADR	60	train	1.75	1.75	0.0000%
MEGlobalADR	61	train	1.15	1.15	0.0000%
MEGlobalADR	62	train	1.1	0.95	13.6364%
MEGlobalADR	63	train	1.2	1.2	0.0000%
MEGlobalADR	64	train	0.95	0.95	0.0000%
MEGlobalADR	65	train	1.15	1.15	0.0000%
MEGlobalADR	66	train	1	0.95	5.0000%
MEGlobalADR	67	train	1.35	1.25	7.4074%
MEGlobalADR	68	train	1.15	1.1	4.3478%
MEGlobalADR	69	train	1.3	1.3	0.0000%
MEGlobalADR	70	train	0.65	0.7	7.6923%
MEGlobalADR	71	train	0.9	0.9	0.0000%
MEGlobalADR	72	train	0.6	0.6	0.0000%
MEGlobalADR	73	train	1.05	1	4.7619%
MEGlobalADR	74	train	1.5	1.5	0.0000%
MEGlobalADR	75	train	1.2	1.2	0.0000%
MEGlobalADR	76	train	1	1	0.0000%
MEGlobalADR	77	train	1.35	1.35	0.0000%
MEGlobalADR	78	train	1.15	1.15	0.0000%
MEGlobalADR	79	train	0.65	0.65	0.0000%
MEGlobalADR	80	train	0.95	0.9	5.2632%
MEGlobalADR	81	train	1.5	1.45	3.3333%
MEGlobalADR	82	train	1.3	1.35	3.8462%
MEGlobalADR	83	train	0.9	0.9	0.0000%
MEGlobalADR	84	train	1	1	0.0000%
MEGlobalADR	85	train	1	1	0.0000%



## ANEXOS- Resultados Experimentais

Modelo	Amostra	Set	y	y'	Erro Abs(%)
MEGlobalADR	86	train	1.1	1.1	0.0000%
MEGlobalADR	87	train	1.25	1.3	4.0000%
MEGlobalADR	88	train	1.1	1.1	0.0000%
MEGlobalADR	89	train	1.15	1.15	0.0000%
MEGlobalADR	90	train	0.9	0.9	0.0000%
MEGlobalADR	91	train	1.15	1.1	4.3478%
MEGlobalADR	92	train	0.6	0.6	0.0000%
MEGlobalADR	93	train	1.1	1.1	0.0000%
MEGlobalADR	94	train	1.25	1.25	0.0000%
MEGlobalADR	95	train	1.15	1.1	4.3478%
MEGlobalADR	96	train	1.05	1.05	0.0000%
MEGlobalADR	97	train	1.05	1.05	0.0000%
MEGlobalADR	98	train	1.1	1.1	0.0000%
MEGlobalADR	99	train	0.75	0.75	0.0000%
MEGlobalADR	100	train	1.05	1.1	4.7619%
MEGlobalADR	101	train	1.1	1.1	0.0000%
MEGlobalADR	102	train	1.05	1.05	0.0000%
MEGlobalADR	103	train	1.15	1.4	21.7391%
MEGlobalADR	104	train	1.75	1.6	8.5714%
MEGlobalADR	105	train	1.05	1	4.7619%
MEGlobalADR	106	train	1.6	1.6	0.0000%
MEGlobalADR	107	train	1.15	1.2	4.3478%
MEGlobalADR	108	train	1.05	1.1	4.7619%
MEGlobalADR	109	train	1.2	1.2	0.0000%
MEGlobalADR	110	train	1.05	1.05	0.0000%
MEGlobalADR	111	train	1.8	1.8	0.0000%
MEGlobalADR	112	train	1.9	1.8	5.2632%
MEGlobalADR	113	train	1.35	1.3	3.7037%
MEGlobalADR	114	train	0.95	0.9	5.2632%
MEGlobalADR	115	train	1.05	1.1	4.7619%
MEGlobalADR	116	train	0.8	0.95	18.7500%
MEGlobalADR	117	train	0.8	0.85	6.2500%
MEGlobalADR	118	train	1.25	1.2	4.0000%
MEGlobalADR	119	train	0.7	0.7	0.0000%
MEGlobalADR	120	train	1	1	0.0000%
MEGlobalADR	121	train	0.85	0.9	5.8824%
MEGlobalADR	122	train	1	1	0.0000%
MEGlobalADR	123	train	0.75	0.75	0.0000%
MEGlobalADR	124	train	1.3	1.3	0.0000%
MEGlobalADR	125	train	0.95	1	5.2632%
MEGlobalADR	126	train	0.95	1	5.2632%
MEGlobalADR	127	train	1.2	1.2	0.0000%
MEGlobalADR	128	train	1.05	1	4.7619%
MEGlobalADR	129	train	1.15	1.15	0.0000%
MEGlobalADR	130	train	1.1	1.1	0.0000%
MEGlobalADR	131	train	1.05	1	4.7619%
MEGlobalADR	132	train	1.1	1.1	0.0000%
MEGlobalADR	133	train	1.1	1.15	4.5455%
MEGlobalADR	134	train	1.25	1.2	4.0000%
MEGlobalADR	135	train	1.2	1.2	0.0000%
MEGlobalADR	136	train	1	1	0.0000%
MEGlobalADR	137	train	1.05	1.05	0.0000%
MEGlobalADR	138	train	1.1	1.05	4.5455%

## ANEXOS- Resultados Experimentais

Modelo	Amostra	Set	y	y'	Erro Abs(%)
MEGlobalADR	139	train	1.2	1.2	0.0000%
MEGlobalADR	140	train	1.15	1.1	4.3478%
MEGlobalADR	141	train	1.15	1.1	4.3478%
MEGlobalADR	142	train	1.3	1.35	3.8462%
MEGlobalADR	143	train	1.3	1.3	0.0000%
MEGlobalADR	144	train	1	0.95	5.0000%
MEGlobalADR	145	train	1.05	1.1	4.7619%
MEGlobalADR	146	train	1.25	1.25	0.0000%
MEGlobalADR	147	train	1.15	1.2	4.3478%
MEGlobalADR	148	train	0.7	1	42.8571%
MEGlobalADR	149	train	1.15	1.25	8.6957%
MEGlobalADR	150	train	0.95	0.95	0.0000%
MEGlobalADR	151	train	1.2	1.3	8.3333%
MEGlobalADR	152	train	1.2	1.2	0.0000%
MEGlobalADR	153	train	1.05	1.05	0.0000%
MEGlobalADR	154	train	0.75	0.75	0.0000%
MEGlobalADR	155	train	1	1	0.0000%
MEGlobalADR	156	train	1.05	1	4.7619%
MEGlobalADR	157	train	1.05	1.1	4.7619%
MEGlobalADR	158	train	1.1	1.1	0.0000%
MEGlobalADR	159	train	1.25	1.25	0.0000%
MEGlobalADR	160	train	1.15	1.15	0.0000%
MEGlobalADR	161	train	1.25	1.2	4.0000%
MEGlobalADR	162	train	1.05	1	4.7619%
MEGlobalADR	163	train	1.8	1.8	0.0000%
MEGlobalADR	164	train	1.25	1.25	0.0000%
MEGlobalADR	165	train	1.1	1.1	0.0000%
MEGlobalADR	166	train	1	1.1	10.0000%
MEGlobalADR	167	train	1.25	1.2	4.0000%
MEGlobalADR	168	train	1.05	1.1	4.7619%
MEGlobalADR	169	train	1.1	1.15	4.5455%
MEGlobalADR	170	train	1.4	1.35	3.5714%
MEGlobalADR	171	train	1	1	0.0000%
MEGlobalADR	172	train	1.9	1.9	0.0000%
MEGlobalADR	173	train	0.75	0.9	20.0000%
MEGlobalADR	174	train	1	1	0.0000%
MEGlobalADR	175	train	0.75	1.25	66.6667%
MEGlobalADR	176	train	1.25	1.2	4.0000%
MEGlobalADR	177	train	1.95	1.6	17.9487%
MEGlobalADR	178	train	0.9	0.85	5.5556%
MEGlobalADR	179	train	1.05	1.05	0.0000%
MEGlobalADR	180	train	1.2	1.15	4.1667%
MEGlobalADR	181	train	0.9	0.95	5.5556%
MEGlobalADR	182	train	1.2	1.2	0.0000%
MEGlobalADR	183	train	1	1.05	5.0000%
MEGlobalADR	184	train	1.05	1.05	0.0000%
MEGlobalADR	185	train	0.95	1	5.2632%
MEGlobalADR	186	train	0.85	0.85	0.0000%
MEGlobalADR	187	train	1.7	1.4	17.6471%
MEGlobalADR	188	train	1	1	0.0000%
MEGlobalADR	189	train	0.85	0.9	5.8824%
MEGlobalADR	190	train	1.3	1.3	0.0000%
MEGlobalADR	191	train	1.05	1.05	0.0000%

## ANEXOS- Resultados Experimentais

Modelo	Amostra	Set	y	y'	Erro Abs(%)
MEGlobalADR	192	train	1	1	0.0000%
MEGlobalADR	193	train	0.8	0.95	18.7500%
MEGlobalADR	194	train	1.4	1.6	14.2857%
MEGlobalADR	195	train	0.9	0.9	0.0000%
MEGlobalADR	196	train	1.05	1	4.7619%
MEGlobalADR	197	train	1.25	1.2	4.0000%
MEGlobalADR	198	train	1	1	0.0000%
MEGlobalADR	199	train	1.05	1.05	0.0000%
MEGlobalADR	200	train	0.95	1	5.2632%
MEGlobalADR	201	train	1.05	1.05	0.0000%
MEGlobalADR	202	train	1.3	1.35	3.8462%
MEGlobalADR	203	train	1	1	0.0000%
MEGlobalADR	204	train	0.95	0.95	0.0000%
MEGlobalADR	205	train	1.25	1.25	0.0000%
MEGlobalADR	206	train	1.15	1.15	0.0000%
MEGlobalADR	207	train	1	1	0.0000%
MEGlobalADR	208	train	1.2	1.15	4.1667%
MEGlobalADR	209	train	1	1	0.0000%
MEGlobalADR	210	train	1	1	0.0000%
MEGlobalADR	211	train	1.05	1.05	0.0000%
MEGlobalADR	212	train	1	1	0.0000%
MEGlobalADR	213	train	0.9	0.9	0.0000%
MEGlobalADR	214	train	1.05	1.05	0.0000%
MEGlobalADR	215	train	1.2	1.2	0.0000%
MEGlobalADR	216	train	0.95	1.3	36.8421%
MEGlobalADR	217	train	0.85	0.9	5.8824%
MEGlobalADR	218	train	1.1	1.1	0.0000%
MEGlobalADR	219	train	1.05	1.05	0.0000%
MEGlobalADR	220	train	1.2	1.2	0.0000%
MEGlobalADR	221	train	0.95	0.95	0.0000%
MEGlobalADR	222	train	1.25	1.2	4.0000%
MEGlobalADR	223	train	1.1	1.1	0.0000%
MEGlobalADR	224	train	1.35	1.35	0.0000%
MEGlobalADR	225	train	1.1	1.1	0.0000%
MEGlobalADR	226	train	1.05	1.1	4.7619%
MEGlobalADR	227	train	1.05	1.05	0.0000%
MEGlobalADR	228	train	1.05	1.1	4.7619%
MEGlobalADR	229	train	0.9	0.9	0.0000%
MEGlobalADR	230	train	0.95	0.75	21.0526%
MEGlobalADR	231	train	1.2	1.2	0.0000%
MEGlobalADR	232	train	1.35	1.35	0.0000%
MEGlobalADR	233	train	1.15	1.15	0.0000%
MEGlobalADR	234	train	1.6	1.6	0.0000%
MEGlobalADR	235	train	1.35	1.25	7.4074%
MEGlobalADR	236	train	1.1	1	9.0909%
MEGlobalADR	237	train	0.95	0.9	5.2632%
MEGlobalADR	238	train	1.1	1.1	0.0000%
MEGlobalADR	239	train	1.15	1.15	0.0000%
MEGlobalADR	240	train	0.55	1	81.8182%
MEGlobalADR	241	train	0.9	0.9	0.0000%
MEGlobalADR	242	train	1.05	1.05	0.0000%
MEGlobalADR	243	train	1.2	1.1	8.3333%
MEGlobalADR	244	train	0.9	0.85	5.5556%

## ANEXOS- Resultados Experimentais

Modelo	Amostra	Set	y	y'	Erro Abs(%)
MEGlobalADR	245	train	0.75	0.7	6.6667%
MEGlobalADR	246	train	1.15	1.15	0.0000%
MEGlobalADR	247	train	1	0.9	10.0000%
MEGlobalADR	248	train	0.9	0.9	0.0000%
MEGlobalADR	249	train	0.75	0.75	0.0000%
MEGlobalADR	250	train	1	1	0.0000%
MEGlobalADR	251	train	1.1	1.1	0.0000%
MEGlobalADR	252	train	1.35	1.35	0.0000%
MEGlobalADR	253	train	1.05	1.1	4.7619%
MEGlobalADR	254	train	0.95	0.95	0.0000%
MEGlobalADR	255	train	0.95	0.95	0.0000%
MEGlobalADR	256	train	1	1	0.0000%
MEGlobalADR	257	train	1.15	1.15	0.0000%
MEGlobalADR	258	train	1.25	1	20.0000%
MEGlobalADR	259	train	1.5	1.4	6.6667%
MEGlobalADR	260	train	1.05	1	4.7619%
MEGlobalADR	261	train	1.15	1.2	4.3478%
MEGlobalADR	262	train	1.1	1.2	9.0909%
MEGlobalADR	263	train	1.35	1.35	0.0000%
MEGlobalADR	264	train	1.25	1.3	4.0000%
MEGlobalADR	265	train	0.9	0.9	0.0000%
MEGlobalADR	266	train	0.95	0.95	0.0000%
MEGlobalADR	267	train	1.2	1.2	0.0000%
MEGlobalADR	268	train	1.2	1.2	0.0000%
MEGlobalADR	269	train	1.3	1.35	3.8462%
MEGlobalADR	270	train	1.3	1.3	0.0000%
MEGlobalADR	271	train	1	1	0.0000%
MEGlobalADR	272	train	1.4	1.45	3.5714%
MEGlobalADR	273	train	0.95	1	5.2632%
MEGlobalADR	274	train	1.1	1.05	4.5455%
MEGlobalADR	275	train	1.2	1.2	0.0000%
MEGlobalADR	276	train	1.2	1.2	0.0000%
MEGlobalADR	277	train	1.05	0.8	23.8095%
MEGlobalADR	278	train	1.15	1.1	4.3478%
MEGlobalADR	279	train	1	1	0.0000%
MEGlobalADR	280	train	1.15	1.15	0.0000%
MEGlobalADR	281	train	1.15	1.15	0.0000%
MEGlobalADR	282	train	1.75	1.75	0.0000%
MEGlobalADR	283	train	1	1	0.0000%
MEGlobalADR	284	train	1.15	1.15	0.0000%
MEGlobalADR	285	train	1.15	1.15	0.0000%
MEGlobalADR	286	train	1.9	1.9	0.0000%
MEGlobalADR	287	train	0.75	1	33.3333%
MEGlobalADR	288	train	0.95	1	5.2632%
MEGlobalADR	289	train	1.05	1.05	0.0000%
MEGlobalADR	290	train	1.25	1.25	0.0000%
MEGlobalADR	291	train	0.85	0.85	0.0000%
MEGlobalADR	292	train	1.15	1.1	4.3478%
MEGlobalADR	293	train	1.05	1.1	4.7619%
MEGlobalADR	294	train	0.95	0.95	0.0000%
MEGlobalADR	295	train	0.95	0.95	0.0000%
MEGlobalADR	296	train	1	1	0.0000%
MEGlobalADR	297	train	1.15	1.15	0.0000%

## ANEXOS- Resultados Experimentais

Modelo	Amostra	Set	y	y'	Erro Abs(%)
MEGlobalADR	298	train	0.7	0.7	0.0000%
MEGlobalADR	299	train	1.35	1.4	3.7037%
MEGlobalADR	300	train	0.9	0.9	0.0000%
MEGlobalADR	301	train	1.35	1.35	0.0000%
MEGlobalADR	302	train	1.05	0.9	14.2857%
MEGlobalADR	303	train	1.3	1.3	0.0000%
MEGlobalADR	304	train	1.05	1.05	0.0000%
MEGlobalADR	305	train	0.95	1	5.2632%
MEGlobalADR	306	train	1.2	1.15	4.1667%
MEGlobalADR	307	train	1.2	1.2	0.0000%
MEGlobalADR	308	train	1.3	1.25	3.8462%
MEGlobalADR	309	train	1.1	1	9.0909%
MEGlobalADR	310	train	1	1	0.0000%
MEGlobalADR	311	train	1.4	1.35	3.5714%
MEGlobalADR	312	train	1.35	1.35	0.0000%
MEGlobalADR	313	train	1.2	1	16.6667%
MEGlobalADR	314	train	1	1	0.0000%
MEGlobalADR	315	train	1	0.95	5.0000%
MEGlobalADR	316	train	1.1	1.1	0.0000%
MEGlobalADR	317	train	1.2	1.15	4.1667%
MEGlobalADR	318	train	0.95	1	5.2632%
MEGlobalADR	319	train	1	1.05	5.0000%
MEGlobalADR	320	train	1	1	0.0000%
MEGlobalADR	321	train	1.05	1	4.7619%
MEGlobalADR	322	train	1.2	1.2	0.0000%
MEGlobalADR	323	train	0.8	0.9	12.5000%
MEGlobalADR	324	train	1.1	1.1	0.0000%
MEGlobalADR	325	train	1.1	1.1	0.0000%
MEGlobalADR	326	train	1.15	1.25	8.6957%
MEGlobalADR	327	train	1.25	1.25	0.0000%
MEGlobalADR	328	train	1.15	1.15	0.0000%
MEGlobalADR	329	train	0.95	0.9	5.2632%
MEGlobalADR	330	train	0.95	0.95	0.0000%

*Tabela A-55: Árvore de Decisão R - Resultados Modelo Estratégico MEGlobalADR*

## Matriz de desempenho

Modelo	Set	Scaled	#Amostras										Soma		Amostras(%)										Erro		Real		Previsão	
			e<5%	e<10%	e<20%	e<30%	e<40%	e<50%	e>50%	Total	Erros			e<5%	e<10%	e<20%	e<30%	e<40%	e<50%	e>50%	Médio	min	max	amplitude	min	max	amplitude			
MEI3	Teste	Y	5	15	21	29	32	35	3	38	7.696127				13.16%	39.47%	55.26%	76.32%	84.21%	92.11%	7.89%	0.2025	0.75	1.9	1.15	0.65	1.9	1.25		
MEI3	Treino	Y	64	85	90	90	90	90	0	90	2.648187				71.11%	94.44%	100.00%	100.00%	100.00%	100.00%	0.00%	0.0294	0.55	1.9	1.35	0.65	1.9	1.25		
MEI3T14	Teste	N	5	15	21	29	32	35	3	38	7.696127				13.16%	39.47%	55.26%	76.32%	84.21%	92.11%	7.89%	0.2025	0.75	1.9	1.15	0.65	1.9	1.25		
MEI3T14	Treino	N	64	85	90	90	90	90	0	90	2.648187				71.11%	94.44%	100.00%	100.00%	100.00%	100.00%	0.00%	0.0294	0.55	1.9	1.35	0.65	1.9	1.25		
MEI4T15	Teste	Y	11	24	39	53	61	66	7	73	17.00591				15.07%	32.88%	53.42%	72.60%	83.56%	90.41%	9.59%	0.2330	0.55	1.75	1.2	0.6	1.5	0.9		
MEI4T15	Treino	Y	90	100	105	105	105	105	0	105	2.161565				85.71%	95.24%	100.00%	100.00%	100.00%	100.00%	0.00%	0.0206	0.5	1.95	1.45	0.5	1.95	1.45		
MEI4T15	Teste	N	11	24	39	53	61	66	7	73	17.00591				15.07%	32.88%	53.42%	72.60%	83.56%	90.41%	9.59%	0.2330	0.55	1.75	1.2	0.6	1.5	0.9		
MEI4T15	Treino	N	90	100	105	105	105	105	0	105	2.161565				85.71%	95.24%	100.00%	100.00%	100.00%	100.00%	0.00%	0.0206	0.5	1.95	1.45	0.5	1.95	1.45		
MEI5	Teste	Y	8	14	27	37	46	47	2	49	10.00603				16.33%	28.57%	55.10%	75.51%	93.88%	95.92%	4.08%	0.2042	0.65	1.8	1.15	0.75	1.75	1		
MEI5	Treino	Y	104	115	117	117	117	117	0	117	1.617682				88.89%	98.29%	100.00%	100.00%	100.00%	100.00%	0.00%	0.0138	0.6	1.9	1.3	0.6	1.9	1.3		
MEI5	Teste	N	8	14	27	37	46	47	2	49	10.00603				16.33%	28.57%	55.10%	75.51%	93.88%	95.92%	4.08%	0.2042	0.65	1.8	1.15	0.75	1.75	1		
MEI5	Treino	N	104	115	117	117	117	117	0	117	1.617682				88.89%	98.29%	100.00%	100.00%	100.00%	100.00%	0.00%	0.0138	0.6	1.9	1.3	0.6	1.9	1.3		
MEI3T14	Teste	Y	29	60	114	134	153	163	15	178	39.13723				16.29%	33.71%	64.04%	75.28%	85.96%	91.57%	8.43%	0.2199	0.5	1.95	1.45	0.55	1.9	1.35		
MEI3T14	Treino	Y	102	128	128	128	128	128	0	128	2.762464				79.69%	100.00%	100.00%	100.00%	100.00%	100.00%	0.00%	0.0216	0.55	1.9	1.35	0.55	1.9	1.35		
MEI3T14	Teste	N	29	60	114	134	153	163	15	178	39.13723				16.29%	33.71%	64.04%	75.28%	85.96%	91.57%	8.43%	0.2199	0.5	1.95	1.45	0.55	1.9	1.35		
MEI3T14	Treino	N	102	128	128	128	128	128	0	128	2.762464				79.69%	100.00%	100.00%	100.00%	100.00%	100.00%	0.00%	0.0216	0.55	1.9	1.35	0.55	1.9	1.35		
MEI4T15	Teste	Y	38	61	108	125	140	150	16	166	34.79237				22.89%	36.75%	65.06%	75.30%	84.34%	90.36%	9.64%	0.2096	0.6	1.9	1.3	0.55	1.9	1.4		
MEI4T15	Treino	Y	145	177	178	178	178	178	0	178	4.277129				81.46%	99.44%	100.00%	100.00%	100.00%	100.00%	0.00%	0.0240	0.5	1.95	1.45	0.5	1.95	1.45		
MEI4T15	Teste	N	38	61	108	125	140	150	16	166	34.79237				22.89%	36.75%	65.06%	75.30%	84.34%	90.36%	9.64%	0.2096	0.6	1.9	1.3	0.55	1.9	1.4		
MEI4T15	Treino	N	145	177	178	178	178	178	0	178	4.277129				81.46%	99.44%	100.00%	100.00%	100.00%	100.00%	0.00%	0.0240	0.5	1.95	1.45	0.5	1.95	1.45		
MEI4T15	Teste	Y	26	45	76	100	120	127	15	142	32.90759				18.31%	31.69%	53.52%	70.42%	84.51%	89.44%	10.56%	0.2317	0.5	1.85	1.35	0.6	1.9	1.3		
MEI4T15	Treino	Y	259	300	312	322	325	328	2	330	13.44513				78.48%	90.91%	94.55%	97.58%	98.48%	99.39%	0.61%	0.0407	0.55	1.95	1.4	0.6	1.9	1.3		
MEI4T15	Teste	N	26	45	76	100	120	127	15	142	32.90759				18.31%	31.69%	53.52%	70.42%	84.51%	89.44%	10.56%	0.2317	0.5	1.85	1.35	0.6	1.9	1.3		
MEI4T15	Treino	N	259	300	312	322	325	328	2	330	13.44513				78.48%	90.91%	94.55%	97.58%	98.48%	99.39%	0.61%	0.0407	0.55	1.95	1.4	0.6	1.9	1.3		

Tabela A-56: Árvores de Decisão R - Mariz de desempenho

## A.4 Gráficos e Tabelas

### A.4.1 Redes Neurais

#### Netconsole

#### Modelo Estratégico 2013




Figura A.1: ME13NC. Valores e médias por amostra c/erro<30%.




Figura A.2: ME13NC. Valores e médias por amostra c/erro<20%.




Figura A.3: ME13NC. Valores por amostra c/erro>30%.




Figura A.4 : ME13NC. Modelação do conj. de Teste. (Prev. vs Real)




Figura A.5: ME2013NC. Número de amostras por categoria de erro.

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	5	13.158%	13.158%
$5\% \leq \epsilon < 10\%$	6	15.789%	28.947%
$10\% \leq \epsilon < 20\%$	8	21.053%	50.000%
$20\% \leq \epsilon < 30\%$	8	21.053%	71.053%
$30\% \leq \epsilon < 40\%$	4	10.526%	81.579%
$40\% \leq \epsilon < 50\%$	5	13.158%	94.737%
$\epsilon \geq 50\%$	2	5.263%	100.000%
<b>Total</b>	<b>38</b>	<b>100%</b>	

Tabela A-57: ME13NC. Número e % de amostras por categoria de erro.

## ANEXOS- Gráficos e Tabelas

	y	y'
max	1.892519	1.748867
min	0.772959	0.703468
Erro médio	Erro médio(%)	
0.253074	0.22907	

Tabela A-58: ME13NC. Valor e % do erro médio e amplitude de resultados

### Modelo Estratégico 2014




Figura A.8: ME14NC. Valores por amostra c/erro>30%.




Figura A.6: ME14NC. Valores e médias por amostra c/erro<30%.




Figura A.9: ME14NC. Modelação do conj. de Teste. (Prev. vs Real)




Figura A.7: ME14NC. Valores e médias por Amostra c/erro<20%.



Figura A.10: ME14NC. Número de amostras por categoria de erro.

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	13	17.808%	17.808%
$5\% \leq \epsilon < 10\%$	15	20.548%	38.356%
$10\% \leq \epsilon < 20\%$	24	32.877%	71.233%
$20\% \leq \epsilon < 30\%$	9	12.329%	83.562%
$30\% \leq \epsilon < 40\%$	7	9.589%	93.151%
$40\% \leq \epsilon < 50\%$	4	5.479%	98.630%
$\epsilon \geq 50\%$	1	1.370%	100.000%
Total	73	100%	

Tabela A-59: ME14NC. Número e % de amostras por categoria de erro.



## ANEXOS- Gráficos e Tabelas

Erro médio	Erro médio(%)	
0.178295128	0.16852649	
	y	y'
max	1.74870524	1.927796
min	0.56243377	0.741094

Tabela A-60: ME14NC. Valor e % do erro médio e amplitude de resultados

### Modelo Estratégico 2015




Figura A.11: : ME15NC. Valores e médias por amostra c/erro<30%.




Figura A.12: ME15NC. Valores e médias por Amostra c/erro<20%.




Figura A.13: ME15NC. Valores por amostra c/erro>30%.




Figura A.14: ME15NC. Modelação do conj. de Teste. (Prev. vs Real)



Figura A.15: ME15NC. Número de amostras por categoria de erro.

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	10	20.408%	20.408%
$5\% \leq \epsilon < 10\%$	4	8.163%	28.571%
$10\% \leq \epsilon < 20\%$	13	26.531%	55.102%
$20\% \leq \epsilon < 30\%$	9	18.367%	73.469%
$30\% \leq \epsilon < 40\%$	8	16.327%	89.796%
$40\% \leq \epsilon < 50\%$	4	8.163%	97.959%
$\epsilon \geq 50\%$	1	2.041%	100.000%
Total	49	100%	

## ANEXOS- Gráficos e Tabelas

Tabela A-61: ME15NC. Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)	
0.2235354	0.193011389	
	y	y'
max	1.822236328	1.556529
min	0.655136161	0.745413

Tabela A-62: ME15NC. Valor e % do erro médio e amplitude de resultados

### Modelo Estratégico 2013 – Conjunto Teste 2014




Figura A.16: ME13T14NC. Valores e médias por amostra c/erro<30%.




Figura A.17: ME13T14NC. Valores e médias por Amostra c/erro<20%.




Figura A.18: ME13T14NC. Valores por amostra c/erro>30%.




Figura A.19: ME13T14NC. Modelação do conj. de Teste. (Prev. vs Real)




Figura A.20: ME13T14NC. Número de amostras por categoria de erro.

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	31	17.416%	17.416%
$5\% \leq \epsilon < 10\%$	36	20.225%	37.640%
$10\% \leq \epsilon < 20\%$	45	25.281%	62.921%
$20\% \leq \epsilon < 30\%$	28	15.730%	78.652%
$30\% \leq \epsilon < 40\%$	18	10.112%	88.764%
$40\% \leq \epsilon < 50\%$	9	5.056%	93.820%
$\epsilon \geq 50\%$	11	6.180%	100.000%
Total	178	100%	

Tabela A-63: ME13T14NC. Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)	
0.2079779	0.197820657	
	y	y'
max	1.963121212	1.770457
min	0.523596214	0.605693

Tabela A-64: ME13T14NC. Valor e % do erro médio e amplitude de resultados

## Modelo Estratégico 2014 – Conjunto Teste 2015




Figura A.22: ME14T15NC. Valores e médias por Amostra c/erro&lt;20%.




Figura A.23: ME14T15NC. Valores por amostra c/erro&gt;30%.




Figura A.21: ME14T15NC. Valores e médias por amostra c/erro&lt;30%.




Figura A.24: ME14T15NC. Modelação do conj. de Teste. (Prev. vs Real)




Figura A.25: ME14T15NC. Número de amostras por categoria de erro.

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	33	19.880%	19.880%
$5\% \leq \epsilon < 10\%$	35	21.084%	40.964%
$10\% \leq \epsilon < 20\%$	48	28.916%	69.880%
$20\% \leq \epsilon < 30\%$	16	9.639%	79.518%
$30\% \leq \epsilon < 40\%$	19	11.446%	90.964%
$40\% \leq \epsilon < 50\%$	8	4.819%	95.783%
$\epsilon \geq 50\%$	7	4.217%	100.000%
Total	166	100%	

Tabela A-65: ME14T15NC. Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.19822146	0.17900766		
	y	y'	delta
max	1.917796641	1.932387	-1%
min	0.600623194	0.555656	7%

Tabela A-66: ME14T15NC. Valor e % do erro médio e amplitude de resultados

**RStudio**

## Modelo Estratégico 2013

## RProp-




Figura A.26: ME13R (RProp-). Valores e médias por amostra c/erro&lt;30%.




Figura A.27: ME13R(RProp-). Valores e médias por Amostra c/erro&lt;20%.

## ANEXOS- Gráficos e Tabelas




Figura A.28: ME13R (RProp-). Valores por amostra c/erro>30%.




Figura A.29: ME13R (RProp-). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.31: ME13R (RProp-). Modelação do conj. de Treino. (Prev. vs Real)




Figura A.32: ME13R (RProp-). Número de amostras por categoria de erro.




Figura A.30: ME13R (RProp-). Modelação do conj. de Treino.

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	7	18.421%	18.421%
$5\% \leq \epsilon < 10\%$	3	7.895%	26.316%
$10\% \leq \epsilon < 20\%$	10	26.316%	52.632%
$20\% \leq \epsilon < 30\%$	9	23.684%	76.316%
$30\% \leq \epsilon < 40\%$	3	7.895%	84.211%
$40\% \leq \epsilon < 50\%$	3	7.895%	92.105%
$\epsilon \geq 50\%$	3	7.895%	100%
Total	38	100%	

Tabela A-67: ME13R (RProp-). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.24867501	0.215172731		
	y	y'	Delta
max	1.892519266	2.063964	9.06%
min	0.772958686	0.644243	-16.65%

Tabela A-68: ME13R (RProp-). Valor e % do erro médio e amplitude de resultados

RProp+




Figura A.33: ME13R (RProp+). Valores e médias por amostra c/erro&lt;30%.




Figura A.34: ME13R (RProp+). Valores e médias por amostra c/erro&lt;20%.




Figura A.35: ME13R (RProp+). Valores por amostra c/erro&gt;30%.




Figura A.36: ME13R (RProp+). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.37: ME13R (RProp+). Modelação do conj. de Treino




Figura A.38: ME13R (RProp+). Modelação do conj. de Treino. (Prev. vs Real)



Figura A.39: ME13R (RProp+). Número de amostras por categoria de erro.

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	6	15.789%	15.789%
$5\% \leq \epsilon < 10\%$	7	18.421%	34.211%
$10\% \leq \epsilon < 20\%$	11	28.947%	63.158%
$20\% \leq \epsilon < 30\%$	8	21.053%	84.211%
$30\% \leq \epsilon < 40\%$	1	2.632%	86.842%
$40\% \leq \epsilon < 50\%$	0	0.000%	86.842%
$\epsilon \geq 50\%$	5	13.158%	100%
Total	38	100%	

Tabela A-69: ME13R (RProp+). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.2505346	23.82%		
	y	y'	Delta
max	1.89251927	2.175056	14.93%
min	0.77295869	0.793501	26.58%

Tabela A-70: ME13R (RProp+). Valor e % do erro médio e amplitude de resultados

## SAG




Figura A.40: ME13R (SAG). Valores e médias por amostra c/erro<30%.




Figura A.41: ME13R (SAG). Valores e médias por Amostra c/erro<20%.




Figura A.42: ME13R (SAG). Valores por amostra c/erro>30%.




Figura A.43: ME13R (SAG). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.44: ME13R (SAG). Modelação do conj. de Treino




Figura A.45: ME13R (SAG). Modelação do conj. de Treino. (Prev. vs Real)




Figura A.46: ME13R (SAG). Número de amostras por categoria de erro.

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	5	13.158%	13.158%
$5\% \leq \epsilon < 10\%$	5	13.158%	26.316%
$10\% \leq \epsilon < 20\%$	11	28.947%	55.263%
$20\% \leq \epsilon < 30\%$	7	18.421%	73.684%
$30\% \leq \epsilon < 40\%$	3	7.895%	81.579%
$40\% \leq \epsilon < 50\%$	2	5.263%	86.842%
$\epsilon \geq 50\%$	5	13.158%	100%
Total	38	100%	

Tabela A-71: ME13R (SAG). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.27565803	24.32%		
	y	y'	Delta
max	1.892519266	2.109993	11.49%
min	0.772958686	0.524322	32.17%

Tabela A-72: ME13R (SAG). Valor e % do erro médio e amplitude de resultados



## RProp-/+ Average




Figura A.47: ME13R (AVG RProp). Valores e médias por amostra c/erro&lt;30%.




Figura A.48: ME13R (RProp Avg). Valores e médias por Amostra c/erro&lt;20%.




Figura A.49: ME13R (RProp Avg). Valores por amostra c/erro&gt;30%.



Figura A.50: ME13R (RProp Avg). Número de amostras por categoria de erro.




Figura A.51: ME13R (RProp Avg). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.52: ME13R (RProp Avg). Modelação do conj. de Treino




Figura A.53: ME13R (RProp Avg). Modelação do conj. de Treino. (Prev. vs Real)

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	5	13.158%	13.158%
$5\% \leq \epsilon < 10\%$	4	10.526%	23.684%
$10\% \leq \epsilon < 20\%$	16	42.105%	65.789%
$20\% \leq \epsilon < 30\%$	8	21.053%	86.842%
$30\% \leq \epsilon < 40\%$	2	5.263%	92.105%
$40\% \leq \epsilon < 50\%$	0	0.000%	92.105%
$\epsilon \geq 50\%$	3	7.895%	100%
Total	38	100%	

Tabela A-73: ME13R (RProp Avg). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.22364202	20.30%		
	y	y'	Delta
max	1.892519266	1.495346	-20.99%
min	0.772958686	0.797663	-3.20%

Tabela A-74: ME13R (RProp Avg). Valor e % do erro médio e amplitude de resultados

## AVG6




Figura A.54: ME13R (AVG6). Valores e médias por amostra c/erro &lt; 30%.




Figura A.55: ME13R (AVG6). Valores e médias por Amostra c/erro &lt; 20%.




Figura A.56: ME13R (AVG6). Valores por amostra c/erro>30%.




Figura A.57: ME13R (AVG6). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.58: ME13R (AVG6). Modelação do conj. de Treino




Figura A.59: ME13R (AVG6). Modelação do conj. de Treino. (Prev. vs Real)



Figura A.60: ME13R (AVG6). Número de amostras por categoria de erro.

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	2	5.263%	5.263%
$5\% \leq \epsilon < 10\%$	6	15.789%	21.053%
$10\% \leq \epsilon < 20\%$	16	42.105%	63.158%
$20\% \leq \epsilon < 30\%$	4	10.526%	73.684%
$30\% \leq \epsilon < 40\%$	5	13.158%	86.842%
$40\% \leq \epsilon < 50\%$	3	7.895%	94.737%
$\epsilon \geq 50\%$	2	5.263%	100%
<b>Total</b>	<b>38</b>	<b>100%</b>	

Tabela A-75: ME13R (AVG6). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.23567562	0.212188918		
	y	y'	Delta
max	1.892519266	1.525483	-0.19394
min	0.772958686	0.748219	0.032007

Tabela A-76: ME13R (AVG6). Valor e % do erro médio e amplitude de resultados

## RProp- (Q-Scaled)




Figura A.61: ME13R (RProp-/Q). Valores e médias por amostra c/erro<30%.




Figura A.62: ME13R (RProp-/Q). Valores e médias por amostra c/erro<20%.




Figura A.63: ME13R (RProp-/Q). Valores por amostra c/erro>30%.




Figura A.64: ME13R (RProp-/Q). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.65: ME13R (RProp-/Q). Modelação do conj. de Treino




Figura A.66: ME13R (RProp-/Q). Modelação do conj. de Treino. (Prev. vs Real)



Figura A.67: ME13R (RProp-/Q). Número de amostras por categoria de erro.

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	7	18.421%	18.421%
$5\% \leq \epsilon < 10\%$	9	23.684%	42.105%
$10\% \leq \epsilon < 20\%$	6	15.789%	57.895%
$20\% \leq \epsilon < 30\%$	10	26.316%	84.211%
$30\% \leq \epsilon < 40\%$	0	0.000%	84.211%
$40\% \leq \epsilon < 50\%$	4	10.526%	94.737%
$\epsilon \geq 50\%$	2	5.263%	100%
<b>Total</b>	<b>38</b>	<b>100%</b>	

Tabela A-77: ME13R (RProp-/Q). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.21170789	18.65%		
	y	y'	Delta
max	1.892519266	1.436741	-24.08%
min	0.772958686	0.739561	4.32%

Tabela A-78: ME13R (RProp-/Q). Valor e % do erro médio e amplitude de resultados

## RProp+ (Q-Scaled)




Figura A.68: ME13R (RProp+/Q). Valores e médias por amostra c/erro<30%.




Figura A.69: ME13R (RProp+/Q). Valores e médias por Amostra c/erro<20%.




Figura A.70: ME13R (RProp+/Q). Valores por amostra c/erro>30%.




Figura A.71: ME13R (RProp+/Q). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.72: ME13R (RProp+/Q). Modelação do conj. de Treino




Figura A.73: ME13R (RProp+/Q). Modelação do conj. de Treino. (Prev. vs Real)



Figura A.74: ME13R (RProp+/Q). Número de amostras por categoria de erro.

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	6	15.789%	15.789%
$5\% \leq \epsilon < 10\%$	7	18.421%	34.211%
$10\% \leq \epsilon < 20\%$	11	28.947%	63.158%
$20\% \leq \epsilon < 30\%$	6	15.789%	78.947%
$30\% \leq \epsilon < 40\%$	4	10.526%	89.474%
$40\% \leq \epsilon < 50\%$	2	5.263%	94.737%
$\epsilon \geq 50\%$	2	5.263%	100%
<b>Total</b>	<b>38</b>	<b>100%</b>	

Tabela A-79: ME13R (RProp+/Q). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.2310875	21.38%		
	Y	y'	Delta
max	1.89251927	1.737631	-8.18%
min	0.77295869	0.451908	41.54%

Tabela A-80: ME13R (RProp+/Q). Valor e % do erro médio e amplitude de resultados

## SAG (Q-Scaled)




Figura A.75: ME13R (SAG/Q). Valores e médias por amostra c/erro&lt;30%.




Figura A.76: ME13R (SAG/Q). Valores e médias por Amostra c/erro&lt;20%.




Figura A.77: ME13R (SAG/Q). Valores por amostra c/erro&gt;30%.




Figura A.78: ME13R (SAG/Q). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.79: ME13R (SAG/Q). Modelação do conj. de Treino




Figura A.80: ME13R (SAG/Q). Modelação do conj. de Treino. (Prev. vs Real)




Figura A.81: ME13R (SAG/Q). Número de amostras por categoria de erro.

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	4	10.526%	10.526%
$5\% \leq \epsilon < 10\%$	4	10.526%	21.053%
$10\% \leq \epsilon < 20\%$	10	26.316%	47.368%
$20\% \leq \epsilon < 30\%$	12	31.579%	78.947%
$30\% \leq \epsilon < 40\%$	4	10.526%	89.474%
$40\% \leq \epsilon < 50\%$	2	5.263%	94.737%
$\epsilon \geq 50\%$	2	5.263%	100%
<b>Total</b>	<b>38</b>	<b>100%</b>	

Tabela A-81: ME13R (SAG/Q). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.252936986	22.44%		
	y	y'	Delta
max	1.89251927	1.509442	-20.24%
min	0.77295869	0.69947	9.51%

Tabela A-82: ME13R (SAG/Q). Valor e % do erro médio e amplitude de resultados

Modelo 2014

RPprop-




Figura A.82: ME14R (RProp-). Valores e médias por amostra c/erro<30%.




Figura A.83: ME14R (RProp-). Valores e médias por Amostra c/erro<20%.






Figura A.84: ME14R (RProp-). Valores por amostra c/erro&gt;30%.




Figura A.87: ME14R (RProp-). Modelação do conj. de Treino. (Prev. vs Real)




Figura A.85: ME14R (RProp-). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.88: ME14R (RProp-). Número de amostras por categoria de erro.




Figura A.86: ME14R (RProp-). Modelação do conj. de Treino

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	16	21.918%	21.918%
$5\% \leq \epsilon < 10\%$	13	17.808%	39.726%
$10\% \leq \epsilon < 20\%$	22	30.137%	69.863%
$20\% \leq \epsilon < 30\%$	14	19.178%	89.041%
$30\% \leq \epsilon < 40\%$	4	5.479%	94.521%
$40\% \leq \epsilon < 50\%$	2	2.740%	97.260%
$\epsilon \geq 50\%$	2	2.740%	100%
Total	73	100%	

Tabela A-83: ME14R (RProp-). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.18162975	16.69%		
	Y	Y'	Delta
max	1.74870524	1.436789	-17.84%
min	0.56243377	0.763782	-35.80%

Tabela A-84: ME14R (RProp-). Valor e % do erro médio e amplitude de resultados

## RProp+




Figura A.89: ME14R (RProp+). Valores e médias por amostra c/erro&lt;30%.




Figura A.90: ME14R (RProp+). Valores e médias por Amostra c/erro&lt;20%




Figura A.91: ME14R (RProp+). Valores por amostra c/erro&gt;30%.




Figura A.92: ME14R (RProp+). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.93: ME14R (RProp+). Modelação do conj. de Treino




Figura A.94: ME14R (RProp+). Modelação do conj. de Treino. (Prev. vs Real)




Figura A.95: ME14R (RProp+). Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	16	21.918%	21.918%
$5\% \leq \epsilon < 10\%$	9	12.329%	34.247%
$10\% \leq \epsilon < 20\%$	23	31.507%	65.753%
$20\% \leq \epsilon < 30\%$	13	17.808%	83.562%
$30\% \leq \epsilon < 40\%$	5	6.849%	90.411%
$40\% \leq \epsilon < 50\%$	3	4.110%	94.521%
$\epsilon \geq 50\%$	4	5.479%	100%
Total	73	100%	

Tabela A-85: ME14R (RProp+). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.20298037	19.32%		
	Y	y'	Delta
max	1.74870524	1.919458	9.76%
min	0.56243377	0.604468	-7.47%

Tabela A-86: ME14R (RProp+). Valor e % do erro médio e amplitude de resultados

SAG




Figura A.96: ME14R (SAG). Valores e médias por amostra c/erro<30%




Figura A.97: ME14R (SAG). Valores e médias por amostra c/erro<20%

## ANEXOS- Gráficos e Tabelas




Figura A.98: ME14R (SAG). Valores por amostra c/erro>30%.




Figura A.99: ME14R (SAG). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.100: ME14R (SAG). Modelação do conj. de Treino




Figura A.101: ME14R (SAG). Modelação do conj. de Treino. (Prev. vs Real)




Figura A.102: ME14R (SAG). Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	17	23.288%	23.288%
$5\% \leq \epsilon < 10\%$	10	13.699%	36.986%
$10\% \leq \epsilon < 20\%$	15	20.548%	57.534%
$20\% \leq \epsilon < 30\%$	12	16.438%	73.973%
$30\% \leq \epsilon < 40\%$	10	13.699%	87.671%
$40\% \leq \epsilon < 50\%$	2	2.740%	90.411%
$\epsilon \geq 50\%$	7	9.589%	100%
Total	73	100%	

Tabela A-87: ME14R (SAG). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.245012	22.87%		
	y	y'	Delta
max	1.748705	2.171107	24.16%
min	0.562434	0.215091	61.76%

Tabela A-88: ME14R (SAG). Valor e % do erro médio e amplitude de resultados

## RProp-/+ Average




Figura A.103: ME14R (AVG RProp). Valores e médias por amostra c/erro<30%.




Figura A.104: ME14R (RProp Avg). Valores e médias por amostra c/erro<20%.




Figura A.105: ME14R (SAG). Valores por amostra c/erro>30%.




Figura A.106: ME14R (RProp Avg). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.107: ME14R (RProp Avg). Modelação do conj. de Treino




Figura A.108: ME14R (RProp Avg). Modelação do conj. de Treino. (Prev. vs Real)




Figura A.109: ME14R (RProp Avg). Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	15	20.548%	20.548%
$5\% \leq \epsilon < 10\%$	11	15.068%	35.616%
$10\% \leq \epsilon < 20\%$	23	31.507%	67.123%
$20\% \leq \epsilon < 30\%$	13	17.808%	84.932%
$30\% \leq \epsilon < 40\%$	6	8.219%	93.151%
$40\% \leq \epsilon < 50\%$	1	1.370%	94.521%
$\epsilon \geq 50\%$	4	5.479%	100%
Total	73	100%	

Tabela A-89: ME14R (RProp Avg). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.193521261	17.78%		
	y	y'	Delta
max	1.748705236	1.551418	-11.28%
min	0.562433767	0.723855	-28.70%

Tabela A-90: ME14R (RProp Avg). Valor e % do erro médio e amplitude de resultados

## AVG6




Figura A.110: ME14R (AVG6). Valores e médias por amostra c/erro<30%.




Figura A.111: ME14R (AVG6). Valores e médias por Amostra c/erro<20%

## ANEXOS- Gráficos e Tabelas




Figura A.112: ME14R (AVG6). Valores por amostra c/erro>30%.




Figura A.113: ME14R (AVG6). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.115: ME14R (AVG6). Modelação do conj. de Treino. (Prev. vs Real)




Figura A.116: ME14R (AVG6). Número de amostras por categoria de erro




Figura A.114: ME14R (AVG6). Modelação do conj. de Treino

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	12	16.438%	16.438%
$5\% \leq \epsilon < 10\%$	8	10.959%	27.397%
$10\% \leq \epsilon < 20\%$	25	34.247%	61.644%
$20\% \leq \epsilon < 30\%$	15	20.548%	82.192%
$30\% \leq \epsilon < 40\%$	5	6.849%	89.041%
$40\% \leq \epsilon < 50\%$	2	2.740%	91.781%
$\epsilon \geq 50\%$	6	8.219%	100%
Total	73	100%	

Tabela A-91: ME14R (AVG6). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.22480981	21.02%		
	y	y'	Delta
max	1.748705236	1.639302	-6.25%
min	0.562433767	0.389946	30.67%

Tabela A-92: ME14R (AVG6). Valor e % do erro médio e amplitude de resultados

## RProp- (Q-Scaled)




Figura A.117: ME14R (RProp-/Q). Valores e médias por amostra c/erro<30%.




Figura A.118: ME14R (RProp-/Q). Valores e médias por amostra c/erro<20%




Figura A.119: ME14R (RProp-/Q). Valores por amostra c/erro>30%.




Figura A.120: ME14R (RProp-/Q). Modelação do conj. de Treino




Figura A.121: ME14R (RProp-/Q). Modelação do conj. de Teste. (Prev. vs Real)






Figura A.122: ME14R (RProp-/Q). Modelação do conj. de Treino. (Prev. vs Real)




Figura A.123: ME14R (RProp-/Q). Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	10	13.699%	13.699%
$5\% \leq \epsilon < 10\%$	10	13.699%	27.397%
$10\% \leq \epsilon < 20\%$	20	27.397%	54.795%
$20\% \leq \epsilon < 30\%$	14	19.178%	73.973%
$30\% \leq \epsilon < 40\%$	7	9.589%	83.562%
$40\% \leq \epsilon < 50\%$	2	2.740%	86.301%
$\epsilon \geq 50\%$	10	13.699%	100%
Total	73	100%	

Tabela A-93: ME14R (RProp-/Q). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.270206	0.248718		
	y	y'	Delta
max	1.748705	2.106078	0.204364
min	0.562434	0.518163	0.078713

Tabela A-94: ME14R (RProp-/Q). Valor e % do erro médio e amplitude de resultados

## RProp+ (Q-Scaled)




Figura A.124: ME14R (RProp+/Q). Valores e médias por amostra c/erro<30%.




Figura A.125: ME14R (RProp+/Q). Valores e médias por Amostra c/erro<20%.




Figura A.126: ME14R (RProp+/Q). Valores por amostra c/erro&gt;30%.




Figura A.127: ME14R (RProp+/Q). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.128: ME14R (RProp+/Q). Modelação do conj. de Treino




Figura A.129: ME14R (RProp+/Q). Modelação do conj. de Treino. (Prev. vs Real)




Figura A.130: ME14R (RProp+/Q). Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	16	21.918%	21.918%
$5\% \leq \epsilon < 10\%$	14	19.178%	41.096%
$10\% \leq \epsilon < 20\%$	16	21.918%	63.014%
$20\% \leq \epsilon < 30\%$	11	15.068%	78.082%
$30\% \leq \epsilon < 40\%$	7	9.589%	87.671%
$40\% \leq \epsilon < 50\%$	4	5.479%	93.151%
$\epsilon \geq 50\%$	5	6.849%	100%
Total	73	100%	

Tabela A-95: ME14R (RProp+/Q). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.21105585	19.41%		
	y	y'	Delta
max	1.7487052	1.743888	-0.28%
min	0.5624338	0.457441	18.67%

Tabela A-96: ME14R (RProp+/Q). Valor e % do erro médio e amplitude de resultados

## SAG (Q-Scaled)




Figura A.131: ME14R (SAG/Q). Valores e médias por amostra c/erro&lt;30%.




Figura A.132: ME14R (SAG/Q). Valores e médias por amostra c/erro&lt;20%




Figura A.133: ME14R (SAG/Q). Valores por amostra c/erro&gt;30%.




Figura A.134: ME14R (SAG/Q). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.135: ME14R (SAG/Q). Modelação do conj. de Treino




Figura A.136: ME14R (SAG/Q). Modelação do conj. de Treino. (Prev. vs Real)



Figura A.137: ME14R (SAG/Q). Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	11	15.068%	15.068%
$5\% \leq \epsilon < 10\%$	17	23.288%	38.356%
$10\% \leq \epsilon < 20\%$	23	31.507%	69.863%
$20\% \leq \epsilon < 30\%$	7	9.589%	79.452%
$30\% \leq \epsilon < 40\%$	4	5.479%	84.932%
$40\% \leq \epsilon < 50\%$	5	6.849%	91.781%
$\epsilon \geq 50\%$	6	8.219%	100%
Total	73	100%	

Tabela A-97: ME14R (SAG/Q). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.22806056	21.33%		
	y	y'	Delta
max	1.748705236	1.803577	3.14%
min	0.562433767	0.188422	66.50%

Tabela A-98: ME14R (SAG/Q). Valor e % do erro médio e amplitude de resultados

## Modelo 2015

### RProp-




Figura A.138: ME15R (RProp-). Valores e médias por amostra c/erro<30%.




Figura A.139: ME15R (RProp-). Valores e médias por Amostra c/erro<20%




Figura A.140: ME15R (RProp-). Valores por amostra c/erro>30%.




Figura A.141: ME15R (RProp-). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.142: ME15R (RProp-). Modelação do conj. de Treino.




Figura A.143: ME15R (RProp-). Modelação do conj. de Treino. (Prev. vs Real)



Figura A.144: ME15R (RProp-). Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	7	14.286%	14.286%
$5\% \leq \epsilon < 10\%$	8	16.327%	30.612%
$10\% \leq \epsilon < 20\%$	12	24.490%	55.102%
$20\% \leq \epsilon < 30\%$	11	22.449%	77.551%
$30\% \leq \epsilon < 40\%$	7	14.286%	91.837%
$40\% \leq \epsilon < 50\%$	3	6.122%	97.959%
$\epsilon \geq 50\%$	1	2.041%	100%
Total	49	100%	

Tabela A-99: ME15R (RProp-). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.231029163	20.02%		
	y	y'	Delta
max	1.822236328	1.948854	6.95%
min	0.655136161	0.757325	-15.60%

Tabela A-100: ME15R (RProp-). Valor e % do erro médio e amplitude de resultados

RProp+




Figura A.145: ME15R (RProp+). Valores e médias por amostra c/erro < 30%.




Figura A.146: ME15R (RProp+). Valores e médias por amostra c/erro < 20%.




Figura A.147: ME15R (RProp+). Valores por amostra c/erro > 30%




Figura A.148: ME15R (RProp+). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.149: ME15R (RProp+). Modelação do conj. de Treino.




Figura A.150: ME15R (RProp+). Modelação do conj. de Treino. (Prev. vs Real)



Figura A.151: ME15R (RProp+). Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	9	18.367%	18.367%
$5\% \leq \epsilon < 10\%$	8	16.327%	34.694%
$10\% \leq \epsilon < 20\%$	8	16.327%	51.020%
$20\% \leq \epsilon < 30\%$	12	24.490%	75.510%
$30\% \leq \epsilon < 40\%$	5	10.204%	85.714%
$40\% \leq \epsilon < 50\%$	3	6.122%	91.837%
$\epsilon \geq 50\%$	4	8.163%	100%
Total	49	100%	

Tabela A-101: ME15R (RProp+). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.24366144	21.81%		
	y	y'	Delta
max	1.822236328	1.623207	-10.92%
min	0.655136161	0.644491	1.62%

Tabela A-102: ME15R (RProp+). Valor e % do erro médio e amplitude de resultados

SAG




Figura A.152: ME15R (SAG). Valores e médias por amostra c/erro<30%.




Figura A.153: ME15R (SAG). Valores e médias por Amostra c/erro<20%

## ANEXOS- Gráficos e Tabelas




Figura A.154: ME15R (SAG). Valores por amostra c/erro>30%




Figura A.155: ME15R (SAG). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.156: ME15R (SAG). Modelação do conj. de Treino.




Figura A.157: ME15R (SAG). Modelação do conj. de Treino. (Prev. vs Real)



Figura A.158: ME15R (SAG). Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	3	6.122%	6.122%
$5\% \leq \epsilon < 10\%$	7	14.286%	20.408%
$10\% \leq \epsilon < 20\%$	10	20.408%	40.816%
$20\% \leq \epsilon < 30\%$	9	18.367%	59.184%
$30\% \leq \epsilon < 40\%$	6	12.245%	71.429%
$40\% \leq \epsilon < 50\%$	9	18.367%	89.796%
$\epsilon \geq 50\%$	5	10.204%	100%
Total	49	100%	

Tabela A-103: ME15R (SAG). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.329471	28.40%		
	y	y'	Delta
max	1.822236	2.339767	28.40%
min	0.655136	0.36225	44.71%

Tabela A-104: ME15R (SAG). Valor e % do erro médio e amplitude de resultados



## RProp-/+ Average




Figura A.159: ME15R (RProp Avg). Valores e médias por amostra c/erro<30%.




Figura A.160: ME15R (RProp Avg). Valores e médias por Amostra c/erro<20%




Figura A.161: ME15R (RProp Avg). Valores por amostra c/erro>30%




Figura A.162: ME15R (RProp Avg). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.163: ME15R (RProp Avg). Modelação do conj. de Treino.




Figura A.164: ME15R (RProp Avg). Modelação do conj. de Treino. (Prev. vs Real)



Figura A.165: ME15R (RProp Avg). Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	16	32.653%	32.653%
$5\% \leq \epsilon < 10\%$	6	12.245%	44.898%
$10\% \leq \epsilon < 20\%$	12	24.490%	69.388%
$20\% \leq \epsilon < 30\%$	3	6.122%	75.510%
$30\% \leq \epsilon < 40\%$	7	14.286%	89.796%
$40\% \leq \epsilon < 50\%$	5	10.204%	100.000%
$\epsilon \geq 50\%$	0	0.000%	100%
Total	49	100%	

Tabela A-105: ME15R (RProp Avg). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.1977432	16.32%		
	y	y'	Delta
max	1.822236328	1.382737	-24.12%
min	0.655136161	0.701939	-7.14%

Tabela A-106: ME15R (RProp Avg). Valor e % do erro médio e amplitude de resultados

## AVG6




Figura A.166: ME15R (AVG6). Valores e médias por amostra c/erro<30%.




Figura A.167: ME15R (AVG6). Valores e médias por Amostra c/erro<20%

## ANEXOS- Gráficos e Tabelas




Figura A.168: ME15R (AVG6). Valores por amostra c/erro>30%




Figura A.169: ME15R (AVG6). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.170: ME15R (AVG6). Modelação do conj. de Treino.




Figura A.171: ME15R (AVG6). Modelação do conj. de Treino. (Prev. vs Real)



Figura A.172: ME15R (AVG6). Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	5	10.204%	10.204%
$5\% \leq \epsilon < 10\%$	6	12.245%	22.449%
$10\% \leq \epsilon < 20\%$	12	24.490%	46.939%
$20\% \leq \epsilon < 30\%$	12	24.490%	71.429%
$30\% \leq \epsilon < 40\%$	8	16.327%	87.755%
$40\% \leq \epsilon < 50\%$	3	6.122%	93.878%
$\epsilon \geq 50\%$	3	6.122%	100%
Total	49	100%	

Tabela A-107: ME15R (AVG6). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.266300107	23.40%		
	y	y'	Delta
max	1.822236328	1.850394	1.55%
min	0.655136161	0.758731	-15.81%

Tabela A-108: ME15R (AVG6). Valor e % do erro médio e amplitude de resultados

## RProp- (Q-Scaled)




Figura A.173: ME15R (RProp-/Q). Valores e médias por amostra c/erro<30%.




Figura A.174: ME15R (RProp-/Q). Valores e médias por Amostra c/erro<20%




Figura A.175: ME15R (RProp-/Q). Valores por amostra c/erro>30%




Figura A.176: ME15R (RProp-/Q). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.177: ME15R (RProp-/Q). Modelação do conj. de Treino.




Figura A.178: ME15R (RProp-/Q). Modelação do conj. de Treino. (Prev. vs Real)



Figura A.179: ME15R (RProp-/Q). Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	8	16.327%	16.327%
$5\% \leq \epsilon < 10\%$	4	8.163%	24.490%
$10\% \leq \epsilon < 20\%$	13	26.531%	51.020%
$20\% \leq \epsilon < 30\%$	11	22.449%	73.469%
$30\% \leq \epsilon < 40\%$	6	12.245%	85.714%
$40\% \leq \epsilon < 50\%$	1	2.041%	87.755%
$\epsilon \geq 50\%$	6	12.245%	100%
Total	49	100%	

Tabela A-109: ME15R (RProp-/Q). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.275121571	23.84%		
	y	y'	Delta
max	1.822236328	2.870738	57.54%
min	0.655136161	0.90333	-37.88%

Tabela A-110: ME15R (RProp-/Q). Valor e % do erro médio e amplitude de resultados

## RProp+ (Q-Scaled)




Figura A.180: ME15R (RProp+/Q). Valores e médias por amostra c/erro<30%.




Figura A.181: ME15R (RProp+/Q). Valores e médias por Amostra c/erro<20%




Figura A.182: ME15R (RProp+/Q). Valores por amostra c/erro&gt;30%




Figura A.183: ME15R (RProp+/Q). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.184: ME15R (RProp+/Q). Modelação do conj. de Treino.




Figura A.185: ME15R (RProp+/Q). Modelação do conj. de Treino. (Prev. vs Real)




Figura A.186: ME15R (RProp+/Q). Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	9	18.367%	18.367%
$5\% \leq \epsilon < 10\%$	3	6.122%	24.490%
$10\% \leq \epsilon < 20\%$	13	26.531%	51.020%
$20\% \leq \epsilon < 30\%$	10	20.408%	71.429%
$30\% \leq \epsilon < 40\%$	7	14.286%	85.714%
$40\% \leq \epsilon < 50\%$	2	4.082%	89.796%
$\epsilon \geq 50\%$	5	10.204%	100%
Total	49	100%	

Tabela A-111: ME15R (RProp+/Q). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.26596882	24.12%		
	y	y'	Delta
max	1.822236328	1.832073	0.54%
min	0.655136161	0.793659	-21.14%

Tabela A-112: ME15R (RProp+/Q). Valor e % do erro médio e amplitude de resultados

## SAG (Q-Scaled)




Figura A.187: ME15R (SAG/Q). Valores e médias por amostra c/erro&lt;30%.




Figura A.188: ME15R (SAG/Q). Valores e médias por amostra c/erro&lt;20%.




Figura A.189: ME15R (SAG/Q). Valores por amostra c/erro&gt;30%.




Figura A.190: ME15R (SAG/Q). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.191: ME15R (SAG/Q). Modelação do conj. de Treino.




Figura A.192: ME15R (SAG/Q). Modelação do conj. de Treino. (Prev. vs Real)



Figura A.193: ME15R (SAG/Q). Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	8	16.327%	16.327%
$5\% \leq \epsilon < 10\%$	6	12.245%	28.571%
$10\% \leq \epsilon < 20\%$	10	20.408%	48.980%
$20\% \leq \epsilon < 30\%$	12	24.490%	73.469%
$30\% \leq \epsilon < 40\%$	5	10.204%	83.673%
$40\% \leq \epsilon < 50\%$	4	8.163%	91.837%
$\epsilon \geq 50\%$	4	8.163%	100%
Total	49	100%	

Tabela A-113: ME15R (SAG/Q). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.2570457	22.70%		
	y	y'	Delta
max	1.822236328	1.912444	9.02%
min	0.655136161	0.695398	-4.03%

Tabela A-114: ME15R (SAG/Q). Valor e % do erro médio e amplitude de resultados

## Modelo 2013 – Conjunto Teste 2014 RPprop-




Figura A.194: ME13T14R (RProp-). Valores e médias por amostra c/erro<30%.




Figura A.195: ME13T14R (RProp-). Valores e médias por Amostra c/erro<20%






Figura A.196: ME13T14R (RProp-). Valores por amostra c/erro&gt;30%




Figura A.197: ME13T14R (RProp-). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.198: ME13T14R (RProp-). Modelação do conj. de Treino.




Figura A.199: ME13T14R (RProp-). Modelação do conj. de Treino. (Prev. vs Real)




Figura A.200: ME13T14R (RProp-). Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	32	17.978%	17.978%
$5\% \leq \epsilon < 10\%$	22	12.360%	30.337%
$10\% \leq \epsilon < 20\%$	39	21.910%	52.247%
$20\% \leq \epsilon < 30\%$	33	18.539%	70.787%
$30\% \leq \epsilon < 40\%$	19	10.674%	81.461%
$40\% \leq \epsilon < 50\%$	10	5.618%	87.079%
$\epsilon \geq 50\%$	23	12.921%	100%
Total	178	100%	

Tabela A-115: ME13T14R (RProp-). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.268027178	24.85%		
	y	y'	Delta
max	1.963121212	2.582347	31.54%
min	0.523596214	0.31185	40.44%

Tabela A-116: ME13T14R (RProp-). Valor e % do erro médio e amplitude de resultados

## RProp+




Figura A.201: ME13T14R (RProp+). Valores e médias por amostra c/erro<30%.




Figura A.202: ME13T14R (RProp+). Valores e médias por amostra c/erro<20%.




Figura A.203: ME13T14R (RProp+). Valores por amostra c/erro>30%




Figura A.204: ME13T14R (RProp+). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.205: ME13T14R (RProp+). Modelação do conj. de Treino.




Figura A.206: ME13T14R (RProp+). Modelação do conj. de Treino. (Prev. vs Real)




Figura A.207: ME13T14R (RProp+). Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	31	17.416%	17.416%
$5\% \leq \epsilon < 10\%$	32	17.978%	35.393%
$10\% \leq \epsilon < 20\%$	51	28.652%	64.045%
$20\% \leq \epsilon < 30\%$	26	14.607%	78.652%
$30\% \leq \epsilon < 40\%$	14	7.865%	86.517%
$40\% \leq \epsilon < 50\%$	6	3.371%	89.888%
$\epsilon \geq 50\%$	18	10.112%	100%
Total	178	100%	

Tabela A-117: ME13T14R (RProp+). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.223524122	21.2%		
	y	y'	Delta
max	1.963121212	2.003433	2.05%
min	0.523596214	0.536568	-2.48%

Tabela A-118: ME13T14R (RProp+). Valor e % do erro médio e amplitude de resultados

## SAG




Figura A.208: ME13T14R (SAG). Valores e médias por amostra c/erro<30%.




Figura A.209: ME13T14R (SAG). Valores e médias por amostra c/erro<20%




Figura A.210: ME13T14R (SAG). Valores por amostra c/erro&gt;30%




Figura A.211: ME13T14R (SAG). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.212: ME13T14R (SAG). Modelação do conj. de Treino.




Figura A.213: ME13T14R (SAG). Modelação do conj. de Treino. (Prev. vs Real)




Figura A.214: ME13T14R (SAG). Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	26	14.607%	14.607%
$5\% \leq \epsilon < 10\%$	35	19.663%	34.270%
$10\% \leq \epsilon < 20\%$	40	22.472%	56.742%
$20\% \leq \epsilon < 30\%$	36	20.225%	76.966%
$30\% \leq \epsilon < 40\%$	21	11.798%	88.764%
$40\% \leq \epsilon < 50\%$	5	2.809%	91.573%
$\epsilon \geq 50\%$	15	8.427%	100%
Total	178	100%	

Tabela A-119: ME13T14R (SAG). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.236260077	21.83%		
	y	y'	Delta
max	1.963121212	2.641104	34.54%
min	0.523596214	0.664453	-26.90%

Tabela A-120: ME13T14R (SAG). Valor e % do erro médio e amplitude de resultados

## RProp-/+ Average




Figura A.215: ME13T14R (RProp Avg). Valores e médias por amostra c/erro<30%.




Figura A.216: ME13T14R (RProp Avg). Valores e médias por Amostra c/erro<20%




Figura A.217: ME13T14R (RProp Avg). Valores por amostra c/erro>30%




Figura A.218: ME13T14R (RProp Avg). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.219: ME13T14R (RProp Avg). Modelação do conj. de Treino.




Figura A.220: ME13T14R (RProp Avg). Modelação do conj. de Treino. (Prev. vs Real)




Figura A.221: ME13T14R (RProp Avg). Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	29	16.292%	16.292%
$5\% \leq \epsilon < 10\%$	31	17.416%	33.708%
$10\% \leq \epsilon < 20\%$	45	25.281%	58.989%
$20\% \leq \epsilon < 30\%$	34	19.101%	78.090%
$30\% \leq \epsilon < 40\%$	20	11.236%	89.326%
$40\% \leq \epsilon < 50\%$	9	5.056%	94.382%
$\epsilon \geq 50\%$	10	5.618%	100%
Total	178	100%	

Tabela A-121: ME13T14R (RProp Avg). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.216174325	20.40%		
	y	y'	Delta
max	1.963121212	1.884086	-4.03%
min	0.523596214	0.66616	-27.23%

Tabela A-122: ME13T14R (RProp Avg). Valor e % do erro médio e amplitude de resultados

## AVG6




Figura A.222: ME13T14R (AVG6). Valores e médias por amostra c/erro<30%.




Figura A.223: ME13T14R (AVG6). Valores e médias por Amostra c/erro<20%




Figura A.224: ME13T14R (AVG6). Valores por amostra c/erro&gt;30%




Figura A.225: ME13T14R (AVG6). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.226: ME13T14R (AVG6). Modelação do conj. de Treino.




Figura A.227: ME13T14R (AVG6). Modelação do conj. de Treino. (Prev. vs Real)




Figura A.228: ME13T14R (AVG6). Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	31	17.416%	17.416%
$5\% \leq \epsilon < 10\%$	35	19.663%	37.079%
$10\% \leq \epsilon < 20\%$	51	28.652%	65.730%
$20\% \leq \epsilon < 30\%$	25	14.045%	79.775%
$30\% \leq \epsilon < 40\%$	17	9.551%	89.326%
$40\% \leq \epsilon < 50\%$	5	2.809%	92.135%
$\epsilon \geq 50\%$	14	7.865%	100%
Total	178	100%	

Tabela A-123: ME13T14R (AVG6). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.212608801	20.29%		
	y	y'	Delta
max	1.963121212	1.994913	1.62%
min	0.523596214	0.702332	-34.14%

Tabela A-124: ME13T14R (AVG6). Valor e % do erro médio e amplitude de resultados

## RProp- (Q-Scaled)




Figura A.229: ME13T14R (RProp-/Q). Valores e médias por amostra c/erro<30%.




Figura A.230: ME13T14R (RProp-/Q). Valores e médias por amostra c/erro<20%




Figura A.231: ME13T14R (RProp-/Q). Valores por amostra c/erro>30%




Figura A.232: ME13T14R (RProp-/Q). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.233: ME13T14R (RProp-/Q). Modelação do conj. de Treino.






Figura A.234: ME13T14R (RProp-/Q). Modelação do conj. de Treino. (Prev. vs Real)



Figura A.235: ME13T14R (RProp-/Q). Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	31	17.416%	17.416%
$5\% \leq \epsilon < 10\%$	32	17.978%	35.393%
$10\% \leq \epsilon < 20\%$	44	24.719%	60.112%
$20\% \leq \epsilon < 30\%$	33	18.539%	78.652%
$30\% \leq \epsilon < 40\%$	14	7.865%	86.517%
$40\% \leq \epsilon < 50\%$	10	5.618%	92.135%
$\epsilon \geq 50\%$	14	7.865%	100%
Total	178	100%	

Tabela A-125: ME13T14R (RProp-/Q). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.22347864	21.26%		
	y	y'	Delta
max	1.963121212	1.826536	-6.96%
min	0.523596214	0.513415	1.94%

Tabela A-126: ME13T14R (RProp-/Q). Valor e % do erro médio e amplitude de resultados

## RProp+ (Q-Scaled)




Figura A.236: ME13T14R (RProp+/Q). Valores e médias por amostra c/erro<30%.




Figura A.237: ME13T14R (RProp+/Q). Valores e médias por Amostra c/erro<20%




Figura A.238: ME13T14R (RProp+/Q). Valores por amostra c/erro&gt;30%




Figura A.239: ME13T14R (RProp+/Q). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.240: ME13T14R (RProp+/Q). Modelação do conj. de Treino.




Figura A.241: ME13T14R (RProp+/Q). Modelação do conj. de Treino. (Prev. vs Real)




Figura A.242: ME13T14R (RProp+/Q). Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	40	22.472%	22.472%
$5\% \leq \epsilon < 10\%$	26	14.607%	37.079%
$10\% \leq \epsilon < 20\%$	47	26.404%	63.483%
$20\% \leq \epsilon < 30\%$	29	16.292%	79.775%
$30\% \leq \epsilon < 40\%$	14	7.865%	87.640%
$40\% \leq \epsilon < 50\%$	6	3.371%	91.011%
$\epsilon \geq 50\%$	16	8.989%	100%
<b>Total</b>	<b>178</b>	<b>100%</b>	

Tabela A-127: ME13T14R (RProp+/Q). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.218781931	20.39%		
	y	y'	Delta
max	1.963121212	1.930024	-1.69%
min	0.523596214	0.566716	8.24%

Tabela A-128: ME13T14R (RProp+/Q). Valor e % do erro médio e amplitude de resultados

## SAG (Q-Scaled)




Figura A.243: ME13T14R (SAG/Q). Valores e médias por amostra c/erro<30%.




Figura A.244: ME13T14R (SAG/Q). Valores e médias por Amostra c/erro<20%.




Figura A.245: ME13T14R (SAG/Q). Valores por amostra c/erro>30




Figura A.246: ME13T14R (SAG/Q). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.247: ME13T14R (SAG/Q). Modelação do conj. de Treino.




Figura A.248: ME13T14R (SAG/Q). Modelação do conj. de Treino. (Prev. vs Real)




Figura A.249: ME13T14R (SAG/Q). Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	38	21.348%	21.348%
$5\% \leq \epsilon < 10\%$	37	20.787%	42.135%
$10\% \leq \epsilon < 20\%$	38	21.348%	63.483%
$20\% \leq \epsilon < 30\%$	20	11.236%	74.719%
$30\% \leq \epsilon < 40\%$	21	11.798%	86.517%
$40\% \leq \epsilon < 50\%$	13	7.303%	93.820%
$\epsilon \geq 50\%$	11	6.180%	100%
Total	178	100%	

Tabela A-129: ME13T14R (SAG/Q). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.214913296	20.20%		
	y	y'	Delta
max	1.963121212	1.833478	-6.60%
min	0.523596214	0.613512	-17.17%

Tabela A-130: ME13T14R (SAG/Q). Valor e % do erro médio e amplitude de resultados

## Modelo 2014 – Conjunto Teste 2015 RProp-




Figura A.250: ME14T15R (RProp-). Valores e médias por amostra c/erro<30%.




Figura A.251: ME14T15R (RProp-). Valores e médias por Amostra c/erro<20%




Figura A.252: ME14T15R (RProp-). Valores por amostra c/erro&gt;30%




Figura A.253: ME14T15R (RProp-). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.255: ME14T15R (RProp-). Modelação do conj. de Treino. (Prev. vs Real)




Figura A.256: ME14T15R (RProp-). Número de amostras por categoria de erro




Figura A.254: ME14T15R (RProp-). Modelação do conj. de Treino.

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	32	19.277%	19.277%
$5\% \leq \epsilon < 10\%$	24	14.458%	33.735%
$10\% \leq \epsilon < 20\%$	40	24.096%	57.831%
$20\% \leq \epsilon < 30\%$	30	18.072%	75.904%
$30\% \leq \epsilon < 40\%$	14	8.434%	84.337%
$40\% \leq \epsilon < 50\%$	10	6.024%	90.361%
$\epsilon \geq 50\%$	16	9.639%	100%
Total	166	100%	

Tabela A-131: ME14T15R (RProp-). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.242949516	21.54%		
	y	y'	Delta
max	1.917796641	2.102066	9.61%
min	0.600623194	0.144773	75.90%

Tabela A-132: ME14T15R (RProp-). Valor e % do erro médio e amplitude de resultados

## RProp+




Figura A.257: ME14T15R (RProp+). Valores e médias por amostra c/erro<30%.




Figura A.258: ME14T15R (RProp+). Valores e médias por Amostra c/erro<20%




Figura A.259: ME14T15R (RProp+). Valores por amostra c/erro>30%




Figura A.260: ME14T15R (RProp+). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.261: ME14T15R (RProp+). Modelação do conj. de Treino.




Figura A.262: ME14T15R (RProp+). Modelação do conj. de Treino. (Prev. vs Real)




Figura A.263: ME14T15R (RProp+). Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	26	15.663%	15.663%
$5\% \leq \epsilon < 10\%$	27	16.265%	31.928%
$10\% \leq \epsilon < 20\%$	44	26.506%	58.434%
$20\% \leq \epsilon < 30\%$	31	18.675%	77.108%
$30\% \leq \epsilon < 40\%$	17	10.241%	87.349%
$40\% \leq \epsilon < 50\%$	10	6.024%	93.373%
$\epsilon \geq 50\%$	11	6.627%	100%
<b>Total</b>	<b>166</b>	<b>100%</b>	

Tabela A-133: ME14T15R (RProp+). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.23313395	21.56%		
	y	y'	Delta
max	1.91779664	2.019379	5.30%
min	0.60062319	0.636233	-5.93%

Tabela A-134: ME14T15R (RProp+). Valor e % do erro médio e amplitude de resultados

SAG




Figura A.264: ME14T15R (SAG). Valores e médias por amostra c/erro<30%.




Figura A.265: ME14T15R (SAG). Valores e médias por Amostra c/erro<20%




Figura A.266: ME14T15R (SAG). Valores por amostra c/erro>30%




Figura A.267: ME14T15R (SAG). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.268: ME14T15R (SAG). Modelação do conj. de Treino.




Figura A.269: ME14T15R (SAG). Modelação do conj. de Treino. (Prev. vs Real)




Figura A.270: ME14T15R (SAG). Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	27	16.265%	16.265%
$5\% \leq \epsilon < 10\%$	28	16.867%	33.133%
$10\% \leq \epsilon < 20\%$	50	30.120%	63.253%
$20\% \leq \epsilon < 30\%$	23	13.855%	77.108%
$30\% \leq \epsilon < 40\%$	22	13.253%	90.361%
$40\% \leq \epsilon < 50\%$	7	4.217%	94.578%
$\epsilon \geq 50\%$	9	5.422%	100%
<b>Total</b>	<b>166</b>	<b>100%</b>	

Tabela A-135: ME14T15R (SAG). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.22723932	20.83%		
	y	y'	Delta
max	1.917796641	2.565004	33.75%
min	0.600623194	0.609927	-1.55%

Tabela A-136: ME14T15R (SAG). Valor e % do erro médio e amplitude de resultados



## RProp-/+ Average




Figura A.271: ME14T15R (RProp Avg). Valores e médias por amostra c/erro<30%.




Figura A.272: ME14T15R (RProp Avg). Valores e médias por Amostra c/erro<20%




Figura A.273: ME14T15R (RProp Avg). Valores por amostra c/erro>30%




Figura A.274: ME14T15R (RProp Avg). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.275: ME14T15R (RProp Avg). Modelação do conj. de Treino.




Figura A.276: ME14T15R (RProp Avg). Modelação do conj. de Treino. (Prev. vs Real)



Figura A.277: ME14T15R (RProp Avg). Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	35	21.084%	21.084%
$5\% \leq \epsilon < 10\%$	27	16.265%	37.349%
$10\% \leq \epsilon < 20\%$	56	33.735%	71.084%
$20\% \leq \epsilon < 30\%$	27	16.265%	87.349%
$30\% \leq \epsilon < 40\%$	10	6.024%	93.373%
$40\% \leq \epsilon < 50\%$	3	1.807%	95.181%
$\epsilon \geq 50\%$	8	4.819%	100%
Total	166	100%	

Tabela A-137: ME14T15R (RProp Avg). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.18965306	17.18%		
	y	y'	Delta
max	1.917796641	1.687163	-12.03%
min	0.600623194	0.778517	-29.62%

Tabela A-138: ME14T15R (RProp Avg). Valor e % do erro médio e amplitude de resultados

## AVG6




Figura A.278: ME14T15R (AVG6). Valores e médias por amostra c/erro<30%.




Figura A.279: ME14T15R (AVG6). Valores e médias por Amostra c/erro<20%




Figura A.280: ME14T15R (AVG6). Valores por amostra c/erro&gt;30%




Figura A.281: ME14T15R (AVG6). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.282: ME14T15R (AVG6). Modelação do conj. de Treino.




Figura A.283: ME14T15R (AVG6). Modelação do conj. de Treino. (Prev. vs Real)




Figura A.284: ME14T15R (AVG6). Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	30	18.072%	18.072%
$5\% \leq \epsilon < 10\%$	31	18.675%	36.747%
$10\% \leq \epsilon < 20\%$	52	31.325%	68.072%
$20\% \leq \epsilon < 30\%$	21	12.651%	80.723%
$30\% \leq \epsilon < 40\%$	12	7.229%	87.952%
$40\% \leq \epsilon < 50\%$	10	6.024%	93.976%
$\epsilon \geq 50\%$	10	6.024%	100%
<b>Total</b>	<b>166</b>	<b>100%</b>	

Tabela A-139: ME14T15R (AVG6). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.208621762	18.98%		
	y	y'	Delta
max	1.917796641	1.802876	-5.99%
min	0.600623194	0.716436	-19.28%

Tabela A-140: ME14T15R (AVG6). Valor e % do erro médio e amplitude de resultados

## RProp- (Q-Scaled)




Figura A.285: ME14T15R (RProp-/Q). Valores e médias por amostra c/erro<30%.




Figura A.286: ME14T15R (RProp-/Q). Valores e médias por Amostra c/erro<20%




Figura A.287: ME14T15R (RProp-/Q). Valores por amostra c/erro>30%




Figura A.288: ME14T15R (RProp-/Q). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.289: ME14T15R (RProp-/Q). Modelação do conj. de Treino.




Figura A.290: ME14T15R (RProp-/Q). Modelação do conj. de Treino. (Prev. vs Real)




Figura A.291: ME14T15R (RProp-/Q). Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	34	20.482%	20.482%
$5\% \leq \epsilon < 10\%$	27	16.265%	36.747%
$10\% \leq \epsilon < 20\%$	40	24.096%	60.843%
$20\% \leq \epsilon < 30\%$	33	19.880%	80.723%
$30\% \leq \epsilon < 40\%$	9	5.422%	86.145%
$40\% \leq \epsilon < 50\%$	11	6.627%	92.771%
$\epsilon \geq 50\%$	12	7.229%	100%
Total	166	100%	

Tabela A-141: ME14T15R (RProp-/Q). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.215990514	19.83%		
	y	y'	Delta
max	1.917796641	1.904929	-0.67%
min	0.600623194	0.634612	-5.66%

Tabela A-142: ME14T15R (RProp-/Q). Valor e % do erro médio e amplitude de resultados

## RProp+ (Q-Scaled)




Figura A.292: ME14T15R (RProp+/Q). Valores e médias por amostra c/erro<30%.




Figura A.293: ME14T15R (RProp+/Q). Valores e médias por Amostra c/erro<20%




Figura A.294: ME14T15R (RProp+/Q). Valores por amostra c/erro>30%




Figura A.295: ME14T15R (RProp+/Q). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.296: ME14T15R (RProp+/Q). Modelação do conj. de Treino.




Figura A.297: ME14T15R (RProp+/Q). Modelação do conj. de Treino. (Prev. vs Real)




Figura A.298: ME14T15R (RProp+/Q). Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	25	15.060%	15.060%
$5\% \leq \epsilon < 10\%$	26	15.663%	30.723%
$10\% \leq \epsilon < 20\%$	51	30.723%	61.446%
$20\% \leq \epsilon < 30\%$	28	16.867%	78.313%
$30\% \leq \epsilon < 40\%$	12	7.229%	85.542%
$40\% \leq \epsilon < 50\%$	12	7.229%	92.771%
$\epsilon \geq 50\%$	12	7.229%	100%
Total	166	100%	

Tabela A-143: ME14T15R (RProp+/Q). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.235419282	21.59%		
	y	y'	Delta
max	1.917796641	1.860813	-2.97%
min	0.600623194	0.368387	38.67%

Tabela A-144: ME14T15R (RProp+/Q). Valor e % do erro médio e amplitude de resultados

## SAG (Q-Scaled)




Figura A.299: ME14T15R (SAG/Q). Valores e médias por amostra c/erro<30%.




Figura A.300: ME14T15R (SAG/Q). Valores e médias por Amostra c/erro<20%




Figura A.301: ME14T15R (SAG/Q). Valores por amostra c/erro>30%




Figura A.302: ME14T15R (SAG/Q). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.303: ME14T15R (SAG/Q). Modelação do conj. de Treino.




Figura A.304: ME14T15R (SAG/Q). Modelação do conj. de Treino. (Prev. vs Real)




Figura A.305: ME14T15R (SAG/Q). Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	28	16.867%	16.867%
$5\% \leq \epsilon < 10\%$	27	16.265%	33.133%
$10\% \leq \epsilon < 20\%$	54	32.530%	65.663%
$20\% \leq \epsilon < 30\%$	22	13.253%	78.916%
$30\% \leq \epsilon < 40\%$	19	11.446%	90.361%
$40\% \leq \epsilon < 50\%$	9	5.422%	95.783%
$\epsilon \geq 50\%$	7	4.217%	100%
<b>Total</b>	<b>166</b>	<b>100%</b>	

Tabela A-145: ME14T15R (SAG/Q). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.212579947	19.12%		
	y	y'	Delta
max	1.917796641	1.835949	-0.04268
min	0.600623194	0.569387	0.052007

Tabela A-146: ME14T15R (SAG/Q). Valor e % do erro médio e amplitude de resultados

## Modelo Global RProp-




Figura A.306: MEGlobalR (RProp-). Valores e médias por amostra c/erro<30%.




Figura A.307: MEGlobalR (RProp-). Valores e médias por amostra c/erro<20%.






Figura A.308: MEGlobalR (RProp-). Valores por amostra c/erro&gt;30%




Figura A.309: MEGlobalR (RProp-). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.310: MEGlobalR (RProp-). Modelação do conj. de Treino.




Figura A.311: MEGlobalR (RProp-). Modelação do conj. de Treino. (Prev. vs Real)




Figura A.312: MEGlobalR (RProp-). Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	21	14.789%	14.789%
$5\% \leq \epsilon < 10\%$	25	17.606%	32.394%
$10\% \leq \epsilon < 20\%$	39	27.465%	59.859%
$20\% \leq \epsilon < 30\%$	23	16.197%	76.056%
$30\% \leq \epsilon < 40\%$	12	8.451%	84.507%
$40\% \leq \epsilon < 50\%$	10	7.042%	91.549%
$\epsilon \geq 50\%$	12	8.451%	100.000%
<b>Total</b>	<b>142</b>	<b>100%</b>	

Tabela A-147: MEGlobalR (RProp-). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.21716852	20.40%		
	y	y'	Delta
max	1.85503924	1.91256	3.10%
min	0.52359621	0.391201	25.29%

Tabela A-148: MEGlobalR (RProp-). Valor e % do erro médio e amplitude de resultados

## RProp+




Figura A.313: MEGlobalR (RProp+). Valores e médias por amostra c/erro<30%.




Figura A.314: MEGlobalR (RProp+). Valores e médias por amostra c/erro<20%.




Figura A.315: MEGlobalR (RProp+). Valores por amostra c/erro>30%




Figura A.316: MEGlobalR (RProp+). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.317: MEGlobalR (RProp+). Modelação do conj. de Treino.




Figura A.318: MEGlobalR (RProp+). Modelação do conj. de Treino. (Prev. vs Real)




Figura A.320: MEGlobalR (SAG). Valores e médias por amostra c/erro<30%.




Figura A.319: MEGlobalR (RProp+). Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	30	21.127%	21.127%
$5\% \leq \epsilon < 10\%$	24	16.901%	38.028%
$10\% \leq \epsilon < 20\%$	32	22.535%	60.563%
$20\% \leq \epsilon < 30\%$	25	17.606%	78.169%
$30\% \leq \epsilon < 40\%$	11	7.746%	85.915%
$40\% \leq \epsilon < 50\%$	7	4.930%	90.845%
$\epsilon \geq 50\%$	13	9.155%	100.000%
<b>Total</b>	<b>142</b>	<b>100%</b>	

Tabela A-149: MEGlobalR (RProp+). Número e % de amostras por categoria de erro.




Figura A.321: MEGlobalR (SAG). Valores e médias por amostra c/erro<20%.

Erro médio	Erro médio(%)		
0.210808605	20.60%		
	y	y'	Delta
max	1.855039239	1.622274	-12.55%
min	0.523596214	0.468489	-10.52%

Tabela A-150: MEGlobalR (RProp+). Valor e % do erro médio e amplitude de resultados




Figura A.322: MEGlobalR (SAG). Valores por amostra c/erro&gt;30%




Figura A.323: MEGlobalR (SAG). Modelação do conj. de Treino.




Figura A.324: MEGlobalR (SAG). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.325: MEGlobalR (SAG). Modelação do conj. de Treino. (Prev. vs Real)




Figura A.326: MEGlobalR (SAG). Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	20	14.085%	14.085%
$5\% \leq \epsilon < 10\%$	22	15.493%	29.577%
$10\% \leq \epsilon < 20\%$	38	26.761%	56.338%
$20\% \leq \epsilon < 30\%$	23	16.197%	72.535%
$30\% \leq \epsilon < 40\%$	16	11.268%	83.803%
$40\% \leq \epsilon < 50\%$	8	5.634%	89.437%
$\epsilon \geq 50\%$	15	10.563%	100.000%
Total	142	100%	

Tabela A-151: MEGlobalR (SAG). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.253386147	24.75%		
	y	y'	Delta
max	1.855039239	2.883501	55.44%
min	0.523596214	0.16815	67.89%

Tabela A-152: MEGlobalR (SAG). Valor e % do erro médio e amplitude de resultados

## RProp-/+ Average




Figura A.327: MEGlobalR (RProp Avg). Valores e médias por amostra c/erro&lt;30%.




Figura A.328: MEGlobalR (RProp Avg). Valores e médias por amostra c/erro&lt;20%.




Figura A.329: MEGlobalR (RProp Avg). Valores por amostra c/erro&gt;30%




Figura A.330: MEGlobalR (RProp Avg). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.331: MEGlobalR (RProp Avg). Modelação do conj. de Treino.




Figura A.332: MEGlobalR (RProp Avg). Modelação do conj. de Treino. (Prev. vs Real)




Figura A.333: MEGlobalR (RProp Avg). Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	29	20.423%	20.423%
$5\% \leq \epsilon < 10\%$	23	16.197%	36.620%
$10\% \leq \epsilon < 20\%$	37	26.056%	62.676%
$20\% \leq \epsilon < 30\%$	23	16.197%	78.873%
$30\% \leq \epsilon < 40\%$	13	9.155%	88.028%
$40\% \leq \epsilon < 50\%$	8	5.634%	93.662%
$\epsilon \geq 50\%$	9	6.338%	100.000%
<b>Total</b>	<b>142</b>	<b>100%</b>	

Tabela A-153: MEGlobalR (RProp Avg). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.197832518	19.08%		
	y	y'	Delta
max	1.855039239	1.778652	-4.12%
min	0.523596214	0.496294	5.21%

Tabela A-154: MEGlobalR (RProp Avg). Valor e % do erro médio e amplitude de resultados

## AVG6




Figura A.334: MEGlobalR (AVG6). Valores e médias por amostra c/erro<30%.




Figura A.335: MEGlobalR (AVG6). Valores e médias por amostra c/erro<20%.




Figura A.336: MEGlobalR (AVG6). Valores por amostra c/erro&gt;30%




Figura A.337: MEGlobalR (AVG6). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.338: MEGlobalR (AVG6). Modelação do conj. de Treino.




Figura A.339: MEGlobalR (AVG6). Modelação do conj. de Treino. (Prev. vs Real)




Figura A.340: MEGlobalR (AVG6). Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	20	14.085%	14.085%
$5\% \leq \epsilon < 10\%$	22	15.493%	29.577%
$10\% \leq \epsilon < 20\%$	42	29.577%	59.155%
$20\% \leq \epsilon < 30\%$	22	15.493%	74.648%
$30\% \leq \epsilon < 40\%$	15	10.563%	85.211%
$40\% \leq \epsilon < 50\%$	13	9.155%	94.366%
$\epsilon \geq 50\%$	8	5.634%	100.000%
<b>Total</b>	<b>142</b>	<b>100%</b>	

Tabela A-155: MEGlobalR (AVG6). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.222408361	21.05%		
	y	y'	Delta
max	1.855039239	1.779397	-4.08%
min	0.523596214	0.264627	49.46%

Tabela A-156: MEGlobalR (AVG6). Valor e % do erro médio e amplitude de resultados

## RProp- (Q-Scaled)




Figura A.341: MEGlobalR (RProp-Q). Valores e médias por amostra c/erro&lt;30%.




Figura A.342: MEGlobalR (RProp-Q). Valores e médias por amostra c/erro&lt;20%.




Figura A.343: MEGlobalR (RProp-Q). Valores por amostra c/erro&gt;30%




Figura A.344: MEGlobalR (RProp-Q). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.345: MEGlobalR (RProp-Q). Modelação do conj. de Treino.






Figura A.346: MEGlobalR (RProp-/Q). Modelação do conj. de Treino. (Prev. vs Real)




Figura A.347: MEGlobalR (RProp-/Q). Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	22	15.493%	15.493%
$5\% \leq \epsilon < 10\%$	28	19.718%	35.211%
$10\% \leq \epsilon < 20\%$	32	22.535%	57.746%
$20\% \leq \epsilon < 30\%$	21	14.789%	72.535%
$30\% \leq \epsilon < 40\%$	16	11.268%	83.803%
$40\% \leq \epsilon < 50\%$	7	4.930%	88.732%
$\epsilon \geq 50\%$	16	11.268%	100.000%
<b>Total</b>	<b>142</b>	<b>100%</b>	

Tabela A-157: MEGlobalR (RProp-/Q). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.2749433	24.79%		
	y	y'	Delta
max	1.963121212	2.351261	19.77%
min	0.572174936	0.59513	-4.01%

Tabela A-158: MEGlobalR (RProp-/Q). Valor e % do erro médio e amplitude de resultados

## RProp+ (Q-Scaled)




Figura A.348: MEGlobalR (RProp+/Q). Valores e médias por amostra c/erro<30%.




Figura A.349: MEGlobalR (RProp+/Q). Valores e médias por amostra c/erro<20%.




Figura A.350: MEGlobalR (RProp+/Q). Valores por amostra c/erro&gt;30%




Figura A.351: MEGlobalR (RProp+/Q). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.352: MEGlobalR (RProp+/Q). Modelação do conj. de Treino.




Figura A.353: MEGlobalR (RProp+/Q). Modelação do conj. de Treino. (Prev. vs Real)




Figura A.354: MEGlobalR (RProp+/Q). Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	16	11.268%	11.268%
$5\% \leq \epsilon < 10\%$	25	17.606%	28.873%
$10\% \leq \epsilon < 20\%$	29	20.423%	49.296%
$20\% \leq \epsilon < 30\%$	29	20.423%	69.718%
$30\% \leq \epsilon < 40\%$	14	9.859%	79.577%
$40\% \leq \epsilon < 50\%$	11	7.746%	87.324%
$\epsilon \geq 50\%$	18	12.676%	100.000%
<b>Total</b>	<b>142</b>	<b>100%</b>	

Tabela A-159: MEGlobalR (RProp+/Q). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.28164689	25.82%		
	y	y'	Delta
max	1.963121212	1.776955	-9.48%
min	0.572174936	0.419648	26.66%

Tabela A-160: MEGlobalR (RProp+/Q). Valor e % do erro médio e amplitude de resultados

## SAG (Q-Scaled)




Figura A.355: MEGlobalR (SAG/Q). Valores e médias por amostra c/erro<30%.




Figura A.356: MEGlobalR (SAG/Q). Valores e médias por amostra c/erro<20%.




Figura A.357: MEGlobalR (SAG/Q). Valores por amostra c/erro>30%




Figura A.358: MEGlobalR (SAG/Q). Modelação do conj. de Teste. (Prev. vs Real)




Figura A.359: MEGlobalR (SAG/Q). Modelação do conj. de Treino.




Figura A.360: MEGlobalR (SAG/Q). Modelação do conj. de Treino. (Prev. vs Real)

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	21	14.789%	14.789%
$5\% \leq \epsilon < 10\%$	27	19.014%	33.803%
$10\% \leq \epsilon < 20\%$	34	23.944%	57.746%
$20\% \leq \epsilon < 30\%$	24	16.901%	74.648%
$30\% \leq \epsilon < 40\%$	19	13.380%	88.028%
$40\% \leq \epsilon < 50\%$	8	5.634%	93.662%
$\epsilon \geq 50\%$	9	6.338%	100.000%
Total	142	100%	

Tabela A-161: MEGlobalR (SAG/Q). Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.244057596	21.61%		
	y	y'	Delta
max	1.963121212	1.680892	-14.38%
min	0.572174936	-0.00165	100.29%

Tabela A-162: MEGlobalR (SAG/Q). Valor e % do erro médio e amplitude de resultados




Figura A.361: MEGlobalR (SAG/Q). Número de amostras por categoria de erro

## A.4.2 Avaliação Global RNAs

	Avaliação		Número de Amostras								% de Amostras						Amplitude (Real)		Amplitude (Previsão)		Erro		
	Amostras com erro<30%	Amostras com erro<20%	≤5%	5%≤<10%	10%≤<20%	20%≤<30%	30%≤<40%	40%≤<50%	≥50%	Total	≤5%	≤10%	≤20%	≤30%	≤40%	<50%	≥50%	max	min	max	min	médio	médio(%)
Modelo																							
ME13NC	Ligeiro	Médio	5	6	8	8	4	5	2	38	13.16%	28.95%	50.00%	71.05%	81.58%	94.74%	5.26%	1.893	0.773	1.749	0.703	0.253	22.91%
	Bom	ME14NC	13	15	24	9	7	4	1	73	17.81%	38.36%	71.23%	83.56%	93.15%	98.63%	1.37%	1.749	0.562	1.928	0.741	0.178	18.85%
	Mau	ME15NC	10	4	13	9	8	4	1	49	20.41%	28.57%	55.10%	73.47%	89.80%	97.96%	2.04%	1.822	0.655	1.557	0.745	0.224	19.30%
	Ligeiro	Médio	31	36	45	28	18	9	11	178	17.42%	37.64%	62.92%	78.65%	88.76%	93.82%	6.18%	1.963	0.524	1.770	0.606	0.208	19.78%
	Médio	ME14T15NC	33	35	48	16	19	8	7	166	19.88%	40.96%	69.88%	79.52%	90.96%	95.78%	4.22%	1.918	0.601	1.932	0.556	0.198	17.90%
	Ligeiro	Bom	7	3	10	9	3	3	3	38	18.42%	26.32%	52.63%	76.32%	84.21%	92.11%	7.90%	1.893	0.773	2.064	0.644	0.249	21.52%
	Mau	ME13R (Rprop+)	6	7	11	8	1	0	5	38	15.79%	34.21%	63.16%	84.21%	86.84%	86.84%	13.16%	1.893	0.773	2.175	0.794	0.251	23.82%
	Ligeiro	Bom	5	5	11	7	3	2	5	38	13.16%	26.32%	55.26%	73.68%	81.58%	86.84%	13.16%	1.893	0.773	2.110	0.524	0.276	24.32%
	Mau	ME13R (Rprop Avg)	5	4	16	8	2	0	3	38	13.16%	23.68%	65.79%	86.84%	92.11%	92.11%	7.90%	1.893	0.773	1.495	0.798	0.224	20.30%
	Médio	ME13R (gPlex)	2	6	16	4	5	3	2	38	5.26%	21.05%	63.16%	73.68%	86.84%	94.74%	5.26%	1.893	0.773	1.525	0.748	0.236	21.22%
	Ligeiro	Bom	7	9	6	10	0	4	2	38	18.42%	42.11%	57.90%	84.21%	84.21%	94.74%	5.26%	1.893	0.773	1.437	0.740	0.212	18.65%
	Mau	ME13R (Rprop+/Q)	6	7	11	6	4	2	2	38	15.79%	34.21%	63.16%	78.95%	89.47%	94.74%	5.26%	1.893	0.773	1.738	0.452	0.231	21.38%
	Bom	ME13R (SAG/Q)	4	4	10	12	4	2	2	38	10.53%	21.05%	47.37%	78.95%	89.47%	94.74%	5.26%	1.893	0.773	1.509	0.699	0.253	22.44%
	Mau	ME14R (Rprop-)	16	13	22	14	4	2	2	73	21.92%	39.73%	69.86%	89.04%	94.52%	97.26%	2.74%	1.749	0.562	1.437	0.764	0.182	16.69%
	Ligeiro	Bom	16	9	23	13	5	3	4	73	21.92%	34.25%	65.75%	83.56%	90.41%	94.52%	5.48%	1.749	0.562	1.919	0.604	0.203	19.32%
	Ligeiro	Médio	17	10	15	12	10	2	7	73	23.29%	36.99%	57.53%	73.97%	87.67%	90.41%	9.59%	1.749	0.562	2.171	0.215	0.245	22.87%
Mau	ME14R (Rprop Avg)	15	11	23	13	6	1	4	73	20.55%	35.62%	67.12%	84.93%	93.15%	94.52%	5.48%	1.749	0.562	1.551	0.724	0.194	17.78%	
Ligeiro	Médio	12	8	25	15	5	2	6	73	16.44%	27.40%	61.64%	82.19%	89.04%	91.78%	8.22%	1.749	0.562	1.639	0.390	0.225	21.02%	
Ligeiro	Médio	10	10	20	14	7	2	10	73	13.70%	27.40%	54.80%	73.97%	83.56%	86.30%	13.70%	1.749	0.562	2.106	0.518	0.270	24.87%	
Mau	ME14R (Rprop+/Q)	16	14	16	11	7	4	5	73	21.92%	41.10%	63.01%	78.08%	87.67%	93.15%	6.85%	1.749	0.562	1.744	0.457	0.211	19.41%	
Ligeiro	Bom	ME14R (SAG/Q)	11	17	23	7	4	5	6	73	15.07%	38.36%	69.86%	79.45%	84.93%	91.78%	8.22%	1.749	0.562	1.804	0.188	0.228	21.33%
Ligeiro	Bom	ME15R (Rprop-)	7	8	12	11	7	3	1	49	14.29%	30.61%	55.10%	77.55%	91.84%	97.96%	2.04%	1.822	0.655	1.949	0.757	0.231	20.02%
Ligeiro	Bom	ME15R (Rprop+)	9	8	8	12	5	3	4	49	18.37%	34.69%	51.02%	75.51%	85.71%	91.84%	8.16%	1.822	0.655	1.623	0.644	0.244	21.81%
Mau	Médio	ME15R (SAG)	3	7	10	9	6	9	5	49	6.12%	20.41%	40.82%	59.18%	71.43%	89.80%	10.20%	1.822	0.655	2.340	0.362	0.329	28.40%
Ligeiro	Médio	ME15R (Rprop Avg)	16	6	12	3	7	5	0	49	32.65%	44.90%	69.39%	75.51%	89.80%	100.00%	0.00%	1.822	0.655	1.383	0.702	0.198	16.32%
Ligeiro	Bom	ME15R (gPlex)	5	6	12	12	8	3	3	49	10.20%	22.45%	46.94%	71.43%	87.76%	93.88%	6.12%	1.822	0.655	1.850	0.759	0.266	23.40%
Mau	Mau	ME15R (Rprop-/Q)	8	4	13	11	6	1	6	49	16.33%	24.49%	51.07%	73.47%	85.71%	87.76%	12.25%	1.822	0.655	2.871	0.903	0.275	23.84%
Ligeiro	Bom	ME15R (Rprop+/Q)	9	3	13	10	7	2	5	49	18.37%	24.49%	51.02%	71.43%	85.71%	89.80%	10.20%	1.822	0.655	1.832	0.794	0.266	24.12%
Mau	Médio	ME15R (SAG/Q)	8	6	10	12	5	4	4	49	16.33%	28.57%	48.98%	73.47%	83.67%	91.84%	8.16%	1.822	0.655	1.912	0.695	0.257	22.70%

Tabela A-163: Tabela Global de Avaliação (Parte I)

	Avaliação		Número de Amostras						% de Amostras						Amplitude (Real)		Amplitude (Previsão)		Erro	
	Anostras com erro<30%	Anostras com erro<20%	5%≤ε<10%	10%≤ε<20%	20%≤ε<30%	30%≤ε<40%	40%≤ε<50%	Total	ε<5%	ε<10%	ε<20%	ε<30%	ε<40%	ε≥50%	max	min	max	min	médio	médio(%)
Modelo																				
ME13T14R (Rprop-)	Médio	Bom	32	39	33	19	10	178	17,98%	30,34%	52,25%	70,79%	81,46%	87,08%	1,963	0,524	2,582	0,312	0,268	24,85%
ME13T14R (Rprop+)	Médio	Médio	31	32	51	26	14	178	17,42%	35,39%	64,05%	78,65%	86,52%	89,89%	1,963	0,524	2,003	0,537	0,224	21,20%
ME13T14R (SAG)	Médio	Bom	26	35	40	36	21	178	14,61%	34,27%	56,74%	76,97%	88,76%	91,57%	1,963	0,524	2,641	0,664	0,236	21,83%
ME13T14R (Rprop Avg)	Ligeiro	Médio	29	31	45	34	20	178	16,29%	33,71%	58,99%	78,09%	89,33%	94,38%	1,963	0,524	1,884	0,666	0,216	20,40%
ME13T14R (gPlex)	Ligeiro	Bom	31	35	51	25	17	178	17,42%	37,08%	65,73%	79,78%	89,33%	92,14%	1,963	0,524	1,995	0,702	0,213	20,29%
ME13T14R (Rprop-/Q)	Médio	Bom	31	32	44	33	14	178	17,42%	35,39%	60,11%	78,65%	86,52%	92,14%	1,963	0,524	1,827	0,513	0,223	21,26%
ME13T14R (Rprop+/Q)	Ligeiro	Bom	40	26	47	29	14	178	22,47%	37,08%	63,48%	79,78%	87,64%	91,01%	1,963	0,524	1,930	0,567	0,219	20,39%
ME13T14R (SAG/Q)	Bom	Bom	38	37	38	20	21	178	21,35%	42,14%	63,48%	74,72%	86,52%	93,82%	1,963	0,524	1,833	0,614	0,215	20,20%
ME14T15R (Rprop-)	Ligeiro	Bom	32	24	40	30	14	166	19,28%	33,74%	57,83%	75,90%	84,34%	90,36%	1,918	0,601	2,102	0,145	0,243	21,54%
ME14T15R (Rprop+)	Ligeiro	Bom	26	27	44	31	17	166	15,66%	31,93%	58,43%	77,11%	87,35%	93,37%	1,918	0,601	2,019	0,636	0,233	21,56%
ME14T15R (SAG)	Médio	Bom	27	28	50	23	7	166	16,27%	33,13%	63,25%	77,11%	90,36%	94,58%	1,918	0,601	2,565	0,610	0,227	20,83%
ME14T15R (Rprop Avg)	Mau	Médio	35	27	56	27	10	166	21,08%	37,35%	71,08%	87,35%	93,37%	95,18%	1,918	0,601	1,687	0,779	0,190	17,18%
ME14T15R (gPlex)	Ligeiro	Bom	30	31	52	21	12	166	18,07%	36,75%	68,07%	80,72%	87,95%	93,98%	1,918	0,601	1,803	0,716	0,209	18,98%
ME14T15R (Rprop-/Q)	Médio	Bom	34	27	40	33	9	166	20,48%	36,75%	60,84%	80,72%	86,15%	92,77%	1,918	0,601	1,905	0,635	0,216	19,83%
ME14T15R (Rprop+/Q)	Ligeiro	Bom	25	26	51	28	12	166	15,06%	30,72%	61,45%	78,31%	85,54%	92,77%	1,918	0,601	1,861	0,368	0,235	21,59%
ME14T15R (SAG/Q)	Médio	Bom	28	27	54	22	19	166	16,87%	33,13%	65,66%	78,92%	90,36%	95,78%	1,918	0,601	1,836	0,569	0,213	19,12%
MEGlobalR (Rprop-)	Médio	Bom	21	25	39	23	12	142	14,79%	32,39%	59,86%	76,06%	84,51%	91,55%	1,855	0,524	1,913	0,391	0,217	20,40%
MEGlobalR (Rprop+)	Médio	Bom	30	24	32	25	11	142	21,13%	38,03%	60,56%	78,17%	85,92%	90,85%	1,855	0,524	1,622	0,468	0,211	20,60%
MEGlobalR (SAG)	Médio	Bom	20	22	38	23	16	142	14,09%	29,58%	56,34%	72,54%	83,80%	89,44%	1,855	0,524	2,884	0,168	0,253	24,75%
MEGlobalR (Rprop Avg)	Ligeiro	Bom	29	23	37	23	13	142	20,42%	36,62%	62,68%	78,87%	88,03%	93,66%	1,855	0,524	1,779	0,496	0,198	19,08%
MEGlobalR (gPlex)	Médio	Bom	20	22	42	22	15	142	14,09%	29,58%	59,16%	74,65%	85,21%	94,37%	1,855	0,524	1,779	0,265	0,222	21,05%
MEGlobalR (Rprop-/Q)	Ligeiro	Médio	22	28	32	21	16	142	15,49%	35,21%	57,75%	72,54%	83,80%	88,73%	1,963	0,572	2,351	0,595	0,275	24,79%
MEGlobalR (Rprop+/Q)	Médio	Bom	16	25	29	29	14	142	11,27%	28,87%	49,30%	69,72%	79,58%	87,32%	1,963	0,572	1,777	0,420	0,282	25,82%
MEGlobalR (SAG/Q)	Ligeiro	Bom	21	27	34	24	19	142	14,79%	33,80%	57,75%	74,65%	88,03%	93,66%	1,963	0,572	1,681	-0,002	0,244	21,61%

Tabela A-164: Tabela de Avaliação Global (Parte II)

### A.4.3 Árvores de Decisão

#### R (CRAN)

Modelo Estratégico 2013




Figura A.362: ME13ADR. Valores e médias por amostra c/erro<30%.




Figura A.363: ME13ADR. Valores e médias por amostra c/erro<20%.




Figura A.364: ME13ADR. Valores por amostra c/erro>30%




Figura A.365: ME13ADR. Modelação do conj. de Teste. (Prev. vs Real)




Figura A.366: ME13ADR. Modelação do conj. de Treino.




Figura A.367: ME13ADR. Modelação do conj. de Treino. (Prev. vs Real)



Figura A.368: ME13ADR. Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	5	13.158%	13.158%
$5\% \leq \epsilon < 10\%$	8	21.053%	34.211%
$10\% \leq \epsilon < 20\%$	8	21.053%	55.263%
$20\% \leq \epsilon < 30\%$	8	21.053%	76.316%
$30\% \leq \epsilon < 40\%$	3	7.895%	84.211%
$40\% \leq \epsilon < 50\%$	3	7.895%	92.105%
$\epsilon \geq 50\%$	3	7.895%	100%
Total	38	100%	

Tabela A-165: ME13ADR. Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.23289474	20.25%		
	y	y'	Delta
max	1.9	1.9	0.00%
min	0.75	0.65	13.33%

Tabela A-166: ME13ADR. Valor e % do erro médio e amplitude de resultados

## Modelo Estratégico 2014




Figura A.369: ME14ADR. Valores e médias por amostra c/erro&lt;30%.




Figura A.370: ME14ADR. Valores e médias por amostra c/erro&lt;20%.






Figura A.371: ME14ADR. Valores por amostra c/erro &gt; 30%




Figura A.372: ME14ADR. Modelação do conj. de Teste. (Prev. vs Real)




Figura A.373: ME14ADR. Modelação do conj. de Treino.




Figura A.374: ME14ADR. Modelação do conj. de Treino. (Prev. vs Real)




Figura A.375: ME14ADR. Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	11	15.068%	15.068%
$5\% \leq \epsilon < 10\%$	12	16.438%	31.507%
$10\% \leq \epsilon < 20\%$	14	19.178%	50.685%
$20\% \leq \epsilon < 30\%$	16	21.918%	72.603%
$30\% \leq \epsilon < 40\%$	6	8.219%	80.822%
$40\% \leq \epsilon < 50\%$	7	9.589%	90.411%
$\epsilon \geq 50\%$	7	9.589%	100%
Total	73	100%	

Tabela A-167: ME14ADR. Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.247260274	23.30%		
	y	y'	Delta
max	1.75	1.5	-14.29%
min	0.55	0.6	-9.09%

Tabela A-168: ME14ADR. Valor e % do erro médio e amplitude de resultados

## Modelo Estratégico 2015




Figura A.376: ME15ADR. Valores e médias por amostra c/erro&lt;30%.




Figura A.377: ME15ADR. Valores e médias por amostra c/erro&lt;20%.




Figura A.378: ME15ADR. Valores por amostra c/erro&gt;30%




Figura A.379: ME15ADR. Modelação do conj. de Teste. (Prev. vs Real)




Figura A.380: ME15ADR. Modelação do conj. de Treino.




Figura A.381: ME15ADR. Modelação do conj. de Treino. (Prev. vs Real)



Figura A.382: ME15ADR. Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	8	16.327%	16.327%
$5\% \leq \epsilon < 10\%$	5	10.204%	26.531%
$10\% \leq \epsilon < 20\%$	14	28.571%	55.102%
$20\% \leq \epsilon < 30\%$	10	20.408%	75.510%
$30\% \leq \epsilon < 40\%$	7	14.286%	89.796%
$40\% \leq \epsilon < 50\%$	3	6.122%	95.918%
$\epsilon \geq 50\%$	2	4.082%	100%
<b>Total</b>	<b>49</b>	<b>100%</b>	

Tabela A-169: ME15ADR. Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.23469388	20.42%		
	y	y'	Delta
max	1.8	1.75	-2.78%
min	0.65	0.75	-15.38%

Tabela A-170: ME15ADR. Valor e % do erro médio e amplitude de resultados

## Modelo Estratégico 2013 – Conjunto Teste 2014




Figura A.383: ME13T14ADR. Valores e médias por amostra c/erro<30%.




Figura A.384: ME13T14ADR. Valores e médias por amostra c/erro<20%.




Figura A.385: ME13T14ADR. Valores por amostra c/erro&gt;30%




Figura A.386: ME13T14ADR. Modelação do conj. de Teste. (Prev. vs Real)




Figura A.387: ME13T14ADR. Modelação do conj. de Treino.




Figura A.388: ME13T14ADR. Modelação do conj. de Treino. (Prev. vs Real)




Figura A.389: ME13T14ADR. Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	29	16.292%	16.292%
$5\% \leq \epsilon < 10\%$	31	17.416%	33.708%
$10\% \leq \epsilon < 20\%$	48	26.966%	60.674%
$20\% \leq \epsilon < 30\%$	26	14.607%	75.281%
$30\% \leq \epsilon < 40\%$	17	9.551%	84.831%
$40\% \leq \epsilon < 50\%$	11	6.180%	91.011%
$\epsilon \geq 50\%$	16	8.989%	100%
Total	178	100%	

Tabela A-171: ME13T14ADR. Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.234550562	21.99%		
	y	y'	Delta
max	1.95	1.9	-2.56%
min	0.5	0.55	-10.00%

Tabela A-172: ME13T14ADR. Valor e % do erro médio e amplitude de resultados

### Modelo Estratégico 2014 – Conjunto Teste 2015




Figura A.390: ME14T15ADR. Valores e médias por amostra c/erro<30%.




Figura A.391: ME14T15ADR. Valores e médias por amostra c/erro<20%.




Figura A.392: ME14T15ADR. Valores por amostra c/erro>30%




Figura A.393: ME14T15ADR. Modelação do conj. de Teste. (Prev. vs Real)




Figura A.394: ME14T15ADR. Modelação do conj. de Treino.




Figura A.395: ME14T15ADR. Modelação do conj. de Treino. (Prev. vs Real)




Figura A.397: MEGlobalADR. Valores e médias por amostra c/erro<30%.




Figura A.396: ME14T15ADR. Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	38	22.892%	22.892%
$5\% \leq \epsilon < 10\%$	22	13.253%	36.145%
$10\% \leq \epsilon < 20\%$	46	27.711%	63.855%
$20\% \leq \epsilon < 30\%$	19	11.446%	75.301%
$30\% \leq \epsilon < 40\%$	15	9.036%	84.337%
$40\% \leq \epsilon < 50\%$	10	6.024%	90.361%
$\epsilon \geq 50\%$	16	9.639%	100%
<b>Total</b>	<b>166</b>	<b>100%</b>	

Tabela A-173: ME14T15ADR. Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.230421687	20.96%		
	y	y'	Delta
max	1.9	1.95	2.63%
min	0.6	0.55	8.33%

Tabela A-174: ME14T15ADR. Valor e % do erro médio e amplitude de resultados




Figura A.398: MEGlobalADR. Valores e médias por amostra c/erro<20%.




Figura A.399: MEGlobalADR. Valores por amostra c/erro>30%

## Modelo Estratégico Global




Figura A.400: MEGlobalADR. Modelação do conj. de Teste. (Prev. vs Real)




Figura A.401: MEGlobalADR. Modelação do conj. de Treino.




Figura A.402: MEGlobalADR. Modelação do conj. de Treino. (Prev. vs Real)




Figura A.403: MEGlobalADR. Número de amostras por categoria de erro

	#Amostras	Amostras(%)	Acumulado
$\epsilon < 5\%$	26	18.310%	18.310%
$5\% \leq \epsilon < 10\%$	16	11.268%	29.577%
$10\% \leq \epsilon < 20\%$	33	23.239%	52.817%
$20\% \leq \epsilon < 30\%$	25	17.606%	70.423%
$30\% \leq \epsilon < 40\%$	19	13.380%	83.803%
$40\% \leq \epsilon < 50\%$	7	4.930%	88.732%
$\epsilon \geq 50\%$	16	11.268%	100%
Total	142	100%	

Tabela A-175: MEGlobalADR. Número e % de amostras por categoria de erro.

Erro médio	Erro médio(%)		
0.238732394	23.17%		
	y	y'	Delta
max	1.85	1.9	2.70%
min	0.5	0.6	-20.00%

Tabela A-176: MEGlobalADR. Valor e % do erro médio e amplitude de resultados





A.4.4 Avaliação Global ADs

	Avaliação		Numero de Amostras								% de Amostras						Amplitude (Real)		Amplitude (Previsão)		Erro		
	Amostras com erro<30%	Amostras com erro<20%	e<5%	5%≤e<10%	10%≤e<20%	20%≤e<30%	30%≤e<40%	40%≤e<50%	≥50%	Total	e<5%	5%≤e<10%	10%≤e<20%	20%≤e<30%	30%≤e<40%	40%≤e<50%	≥50%	max	min	max	min	médio	médio (%)
Modelo																							
ME13ADR	Médio	Bom	5	8	8	8	3	3	3	38	13.16%	34.21%	55.26%	76.32%	84.21%	92.11%	7.90%	1.9	0.75	1.9	0.65	0.2329	20.25%
ME14ADR	Ligeiro	Bom	11	12	14	16	6	7	7	73	15.07%	31.51%	50.69%	72.60%	80.82%	90.41%	9.59%	1.75	0.55	1.5	0.6	0.2473	23.30%
ME15ADR	Ligeiro	Médio	8	5	14	10	7	3	2	49	16.33%	26.53%	55.10%	75.51%	89.80%	95.92%	4.08%	1.8	0.65	1.75	0.75	0.2347	20.42%
ME13T14ADR	Médio	Médio	29	31	48	26	17	11	16	178	16.29%	33.71%	60.67%	75.28%	84.83%	91.01%	8.99%	1.95	0.5	1.9	0.55	0.2346	21.99%
ME14T15ADR	Médio	Bom	38	22	46	19	15	10	16	166	22.89%	36.15%	63.86%	75.30%	84.34%	90.36%	9.64%	1.9	0.6	1.95	0.55	0.230	20.96%
MEGlobalADR	Bom	Bom	26	16	33	25	19	7	16	142	18.31%	29.58%	52.82%	70.42%	83.80%	88.73%	11.27%	1.85	0.500	1.9	0.600	0.2387	23.17%

Tabela A-177: Tabela de Avaliação Global ADs

## A.5 Árvores de Decisão

## A.5.1 R (CRAN)

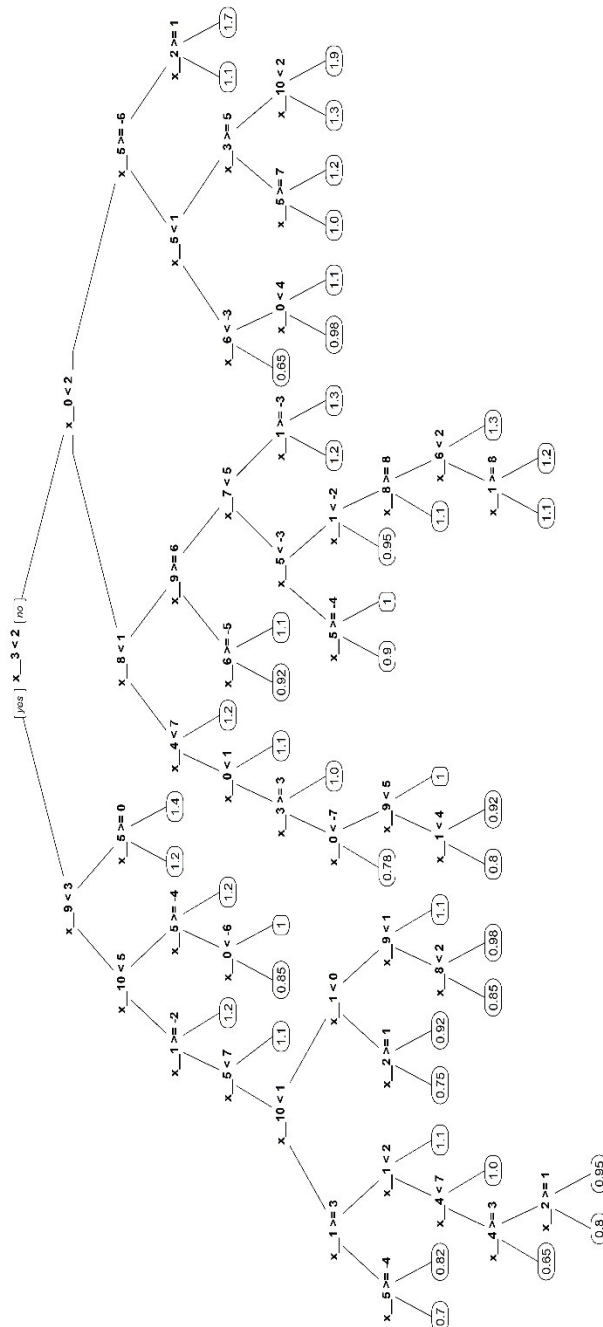
*Modelo Estratégico 2013*

Figura A.404: ME13ADR Topologia da Árvore de Decisão

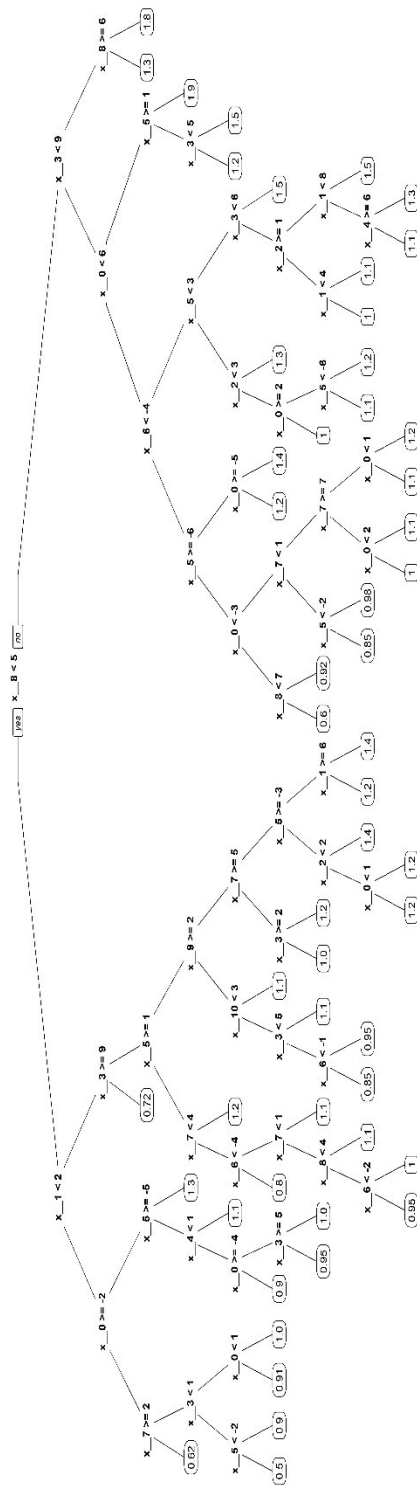
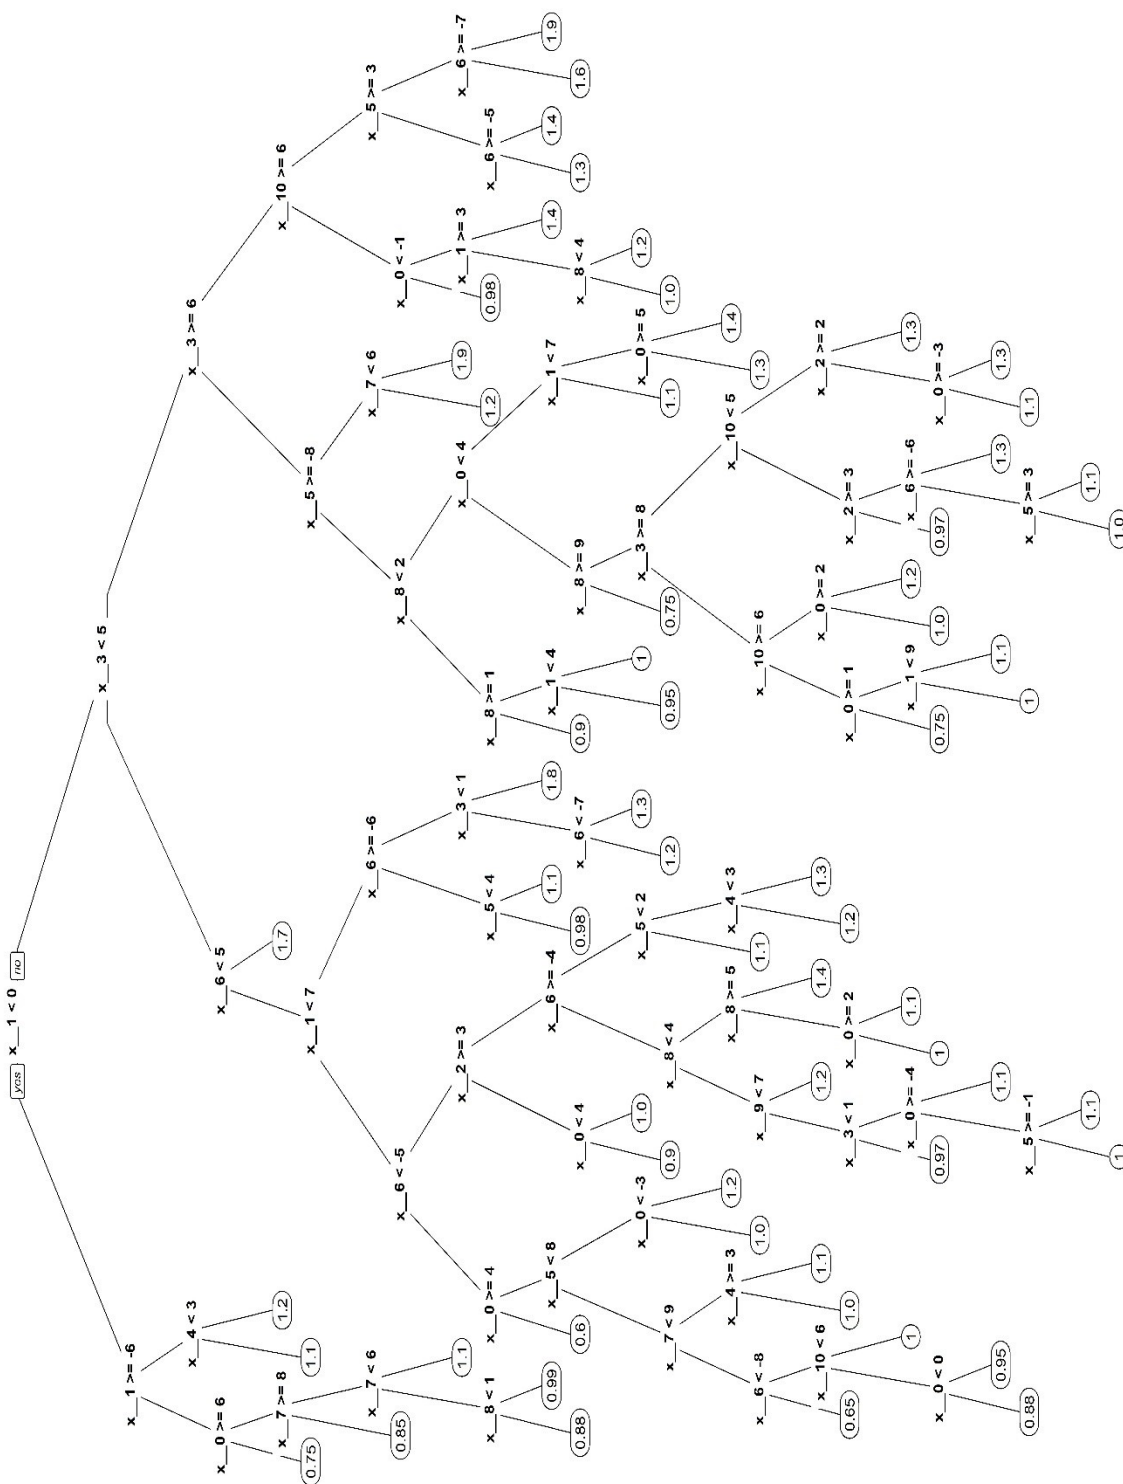
**Modelo Estratégico 2014**

Figura A.405: ME14ADR Topologia da Árvore de Decisão



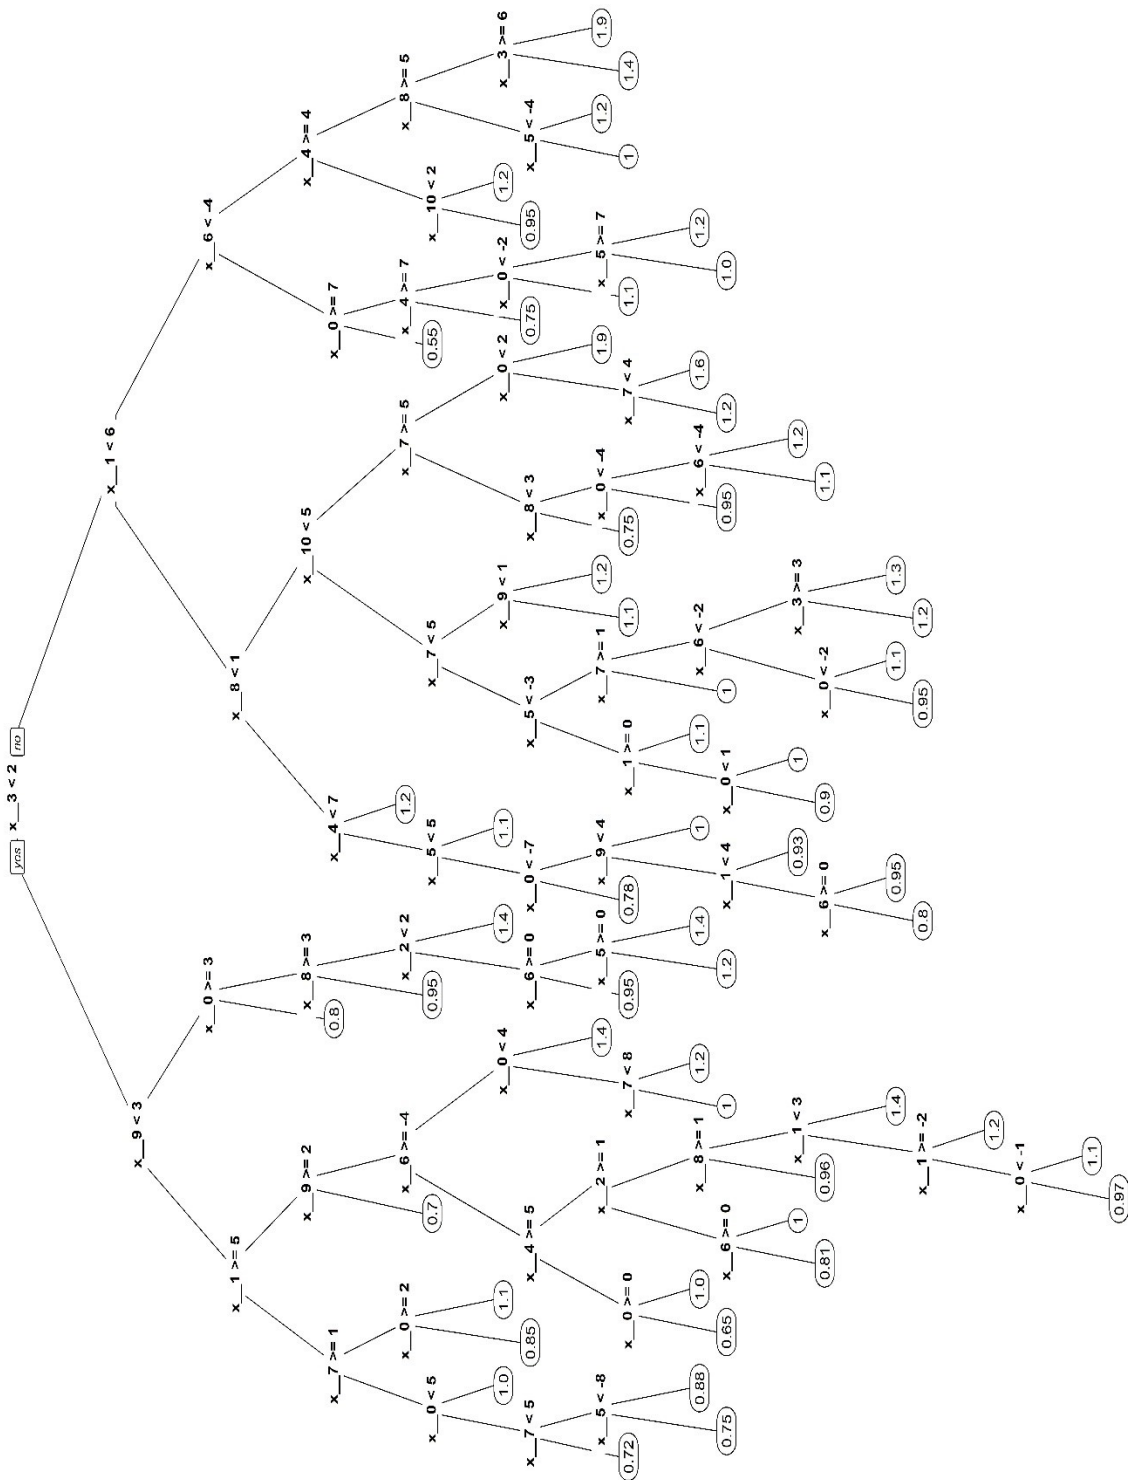
**Modelo Estratégico 2013 – Conjunto Teste 2014**

Figura A.407: ME13T14ADR Topologia da Árvore de Decisão


**Modelo Estratégico 2014 – Conjunto Teste 2015**

Figura A.408: ME14T15ADR Topologia da Árvore de Decisão

**Modelo Estratégico Global**

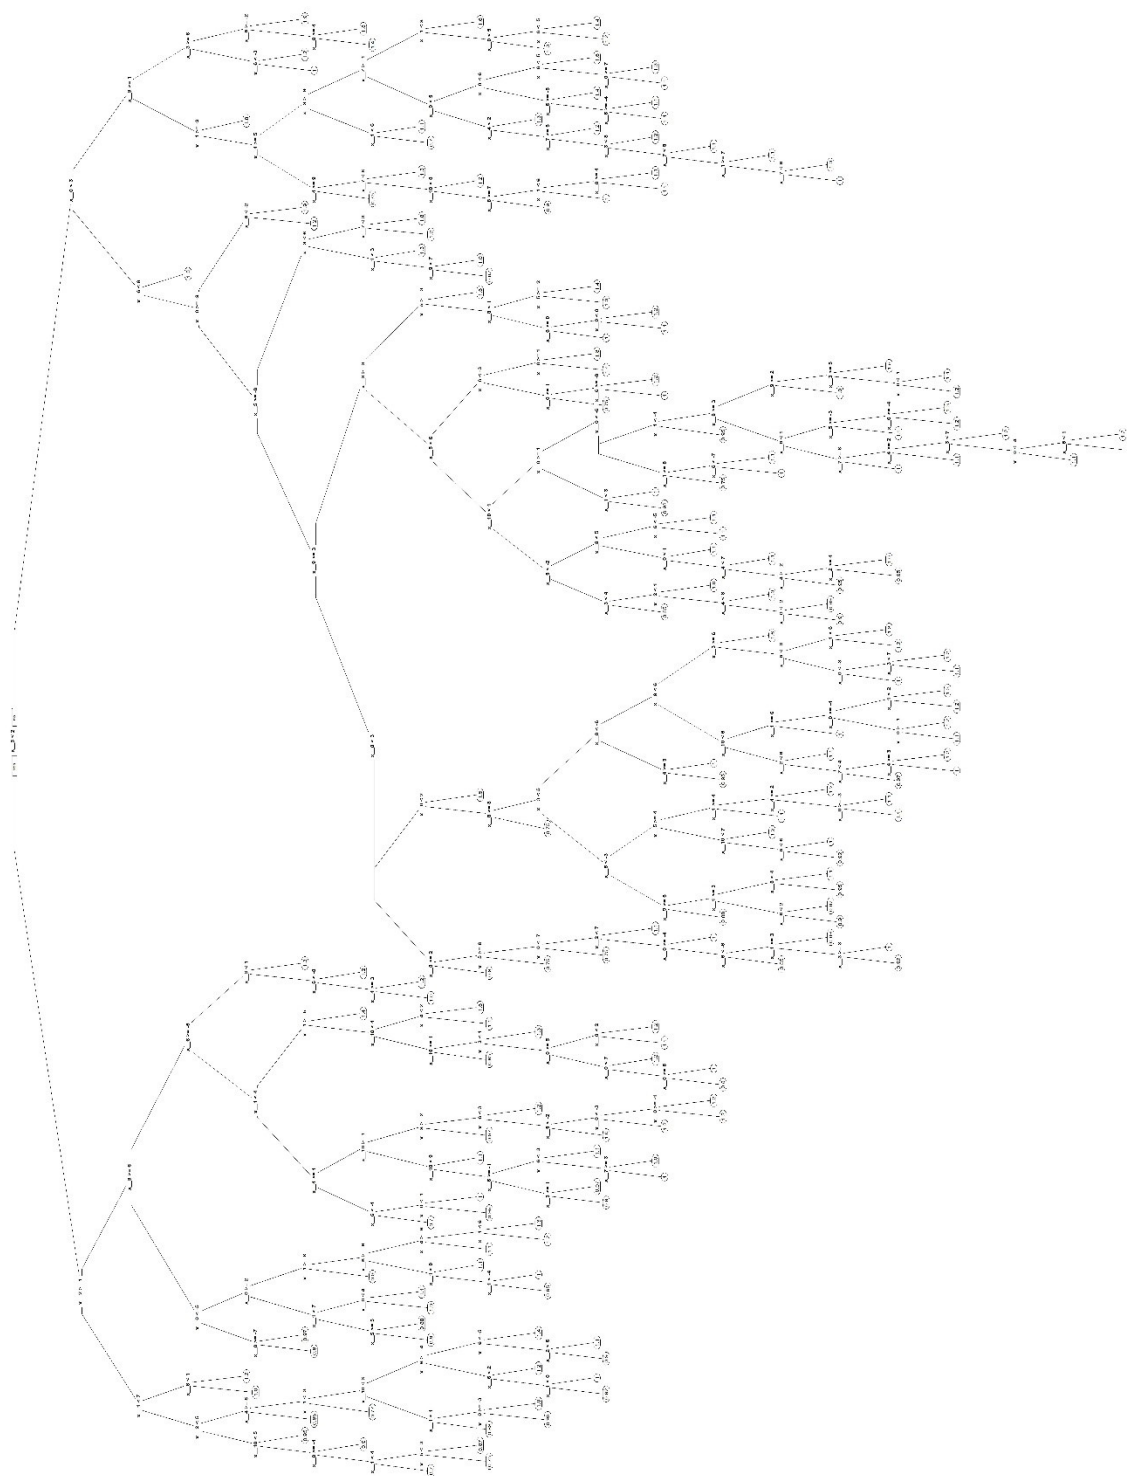


Figura A.409: MEGlobalADR Topologia da Árvore de Decisão

## A.6 Desenvolvimento de Software (Automatização)

Nesta secção é apresentado o desenvolvimento feito de forma a executar as experiências na plataforma R CRAN

### A.6.1 Redes Neurais

#### *Algoritmos RProp-, RProp+, SAG, RProp-/Q, RProp+/Q e SAG/Q*

Modelos ME13, ME14, ME15, ME13T14, ME14T15

```
#Loading needed Libraries
library(readxl)
library(dplyr)
library(neuralnet)

#Attributes
topnn=c(256,256,128,32)
set.seed(110)
n_inputs=11
financial_result="VN"
n_results=1
n_experiments=1
projects=c("Exp I RStudio 2013","Exp I RStudio 2014","Exp I RStudio 2015","Exp I RStudio 2013-2014","Exp I RStudio 2014-2015")
scaled=c("default","question")
for (p in projects) {
  for (sc in scaled){
    #Setting Working Directory
    work_dir=paste("Z:/Experiments/",p,"/",sep="")
    #NeuralNet ANN Algorithms
    algorithms=c("rprop+","rprop-","sag")      #"rprop+","rprop-","slr","sag","backprop"
    n_algorithms=length(algorithms)
    #Load Data
    train <- read.csv(paste(work_dir,"Data/Data_train.csv",sep=""), header=TRUE, sep=",")
    test  <- read.csv(paste(work_dir,"Data/Data_evaluation.csv",sep=""), header=TRUE, sep=",")
    ftrain=train
    fttest=test
    n_samples_train=nrow(train)
    n_samples_test=nrow(test)
    #Groups for Neural Net Testing
    #train - Training Set
    #test - Test Set
    sgroups=c("test","train")
    n_groups=length(sgroups)
    performance_array=array(0,dim=c(n_groups*n_algorithms,20,n_results))
    errors_list<-list()
    print("Start Processing ....")
    count=0
    str_aux_i="No Value"
    #Prepare NN formula
    n <- names(train[,1:n_inputs])
    f <- as.formula(paste("y ~", paste(n[!n %in% "y"], collapse = " + ")))
    count_i=0
    for (c in c(1)){
      count_i=count_i+1
      count_algorithms=0
      for (j in algorithms) {
        train=ftrain
        test=fttest
        print(paste("Algorithm: ", j))
        count_algorithms=count_algorithms+1
        title=paste(str_aux_i,j,collapse="-")
        formatted_train=train[1:n_samples_train,1:11]
        formatted_test=test[1:n_samples_test,1:11]
        formatted_all=rbind(train[1:n_samples_train,1:11],test[1:n_samples_test,1:11])

        if (sc=="default") {
          print("Default Scaled")
          t_train=as.data.frame(t(scale(t(formatted_train), center = FALSE, scale =
array(14,dim=n_samples_train))))#rowSums(abs(formatted_train))))
          t_test=as.data.frame(t(scale(t(formatted_test), center = FALSE, scale = array(14,dim=n_samples_test))))#rowSums(abs(formatted_test))))
        }
      }
    }
  }
}
```



```

if (sc=="question"){
  print("Question Scaled")
  t_train=as.data.frame(t(scale(t(formated_train), center = FALSE, scale = rowSums(abs(formated_train)/10))))
  t_test=as.data.frame(t(scale(t(formated_test), center = FALSE, scale = rowSums(abs(formated_test)/10))))
}

t_train$y=train$y
t_test$y=test$y
train_aux=t_train
test_aux=t_test
nn <- neuralnet(f,data=train_aux,hidden=topnn,err.fct="sse",stepmax=3*1e+02,algorithm = j, act.fct= "logistic", threshold = 0.02,
learningrate = 0.9, linear.output=TRUE)

count_sgroups=0
#par(mfrow=c(1,3))
for (s in sgroups){
  print(paste("START SET ",s,sep=":: "))
  count_sgroups=count_sgroups+1
  if (s=="test") {
    ttt<-test_aux
    title="Conjunto Teste"
  }
  if (s=="train") {
    ttt<-train_aux
    title="Conjunto Treino"
  }
  pr.nn <- compute(nn,ttt[,1:n_inputs])#11])
  pr.nn <- pr.nn$net.result
  amplitude_min_train=min(ttt$y)
  amplitude_max_train=max(ttt$y)
  amplitude_min_test=min(pr.nn_)
  amplitude_max_test=max(pr.nn_)
  xmin=0 #min(ttt$y)
  xmax=max(max(ttt$y),max(pr.nn_))
  ymin=0# min(pr.nn_)
  ymax=xmax #max(pr.nn_)
  errors <- (abs(ttt$y - pr.nn_))/(ttt$y) #in %
  quadratic_errors <- (abs(ttt$y - pr.nn_)^2)
  errors_list<-c(errors_list,list(list(c(1,j,s,data.matrix(ttt$y),pr.nn_,errors,quadratic_errors)))
  average_error <- mean(errors)
  count_less_5=sum(abs(errors) < 0.05)
  count_less_10=sum(abs(errors) < 0.10)
  count_less_20=sum(abs(errors) < 0.20)
  count_less_25=sum(abs(errors) < 0.30)
  count_less_40=sum(abs(errors) < 0.40)
  count_less_50=sum(abs(errors) < 0.50)
  count_more_50=sum(abs(errors) >= 0.50)
  count_100=sum(abs(errors) >= 0)
  performance_array=array(0,dim=c(n_groups*n_algorithms,20,n_results))
  aux_index=(count_algorithms-1)*n_groups+count_sgroups
  performance_array[aux_index,1,count_i]=count_sgroups
  performance_array[aux_index,2,count_i]=count_algorithms
  performance_array[aux_index,3,count_i]=performance_array[aux_index,3,count_i]+count_less_5
  performance_array[aux_index,4,count_i]=performance_array[aux_index,4,count_i]+count_less_10
  performance_array[aux_index,5,count_i]=performance_array[aux_index,5,count_i]+count_less_20
  performance_array[aux_index,6,count_i]=performance_array[aux_index,6,count_i]+count_less_25
  performance_array[aux_index,7,count_i]=performance_array[aux_index,7,count_i]+count_less_40
  performance_array[aux_index,8,count_i]=performance_array[aux_index,8,count_i]+count_less_50
  performance_array[aux_index,9,count_i]=performance_array[aux_index,9,count_i]+count_more_50
  performance_array[aux_index,10,count_i]=performance_array[aux_index,10,count_i]+count_100
  performance_array[aux_index,11,count_i]=performance_array[aux_index,11,count_i]+average_error*count_100
  performance_array[aux_index,12,count_i]=performance_array[aux_index,3,count_i]/performance_array[aux_index,10,count_i]
  performance_array[aux_index,13,count_i]=performance_array[aux_index,4,count_i]/performance_array[aux_index,10,count_i]
  performance_array[aux_index,14,count_i]=performance_array[aux_index,5,count_i]/performance_array[aux_index,10,count_i]
  performance_array[aux_index,15,count_i]=performance_array[aux_index,6,count_i]/performance_array[aux_index,10,count_i]
  performance_array[aux_index,16,count_i]=performance_array[aux_index,7,count_i]/performance_array[aux_index,10,count_i]
  performance_array[aux_index,17,count_i]=performance_array[aux_index,8,count_i]/performance_array[aux_index,10,count_i]
  performance_array[aux_index,18,count_i]=performance_array[aux_index,9,count_i]/performance_array[aux_index,10,count_i]
  performance_array[aux_index,19,count_i]=performance_array[aux_index,10,count_i]/performance_array[aux_index,10,count_i]
  performance_array[aux_index,20,count_i]=performance_array[aux_index,11,count_i]/performance_array[aux_index,10,count_i]
  write(paste(performance_array[aux_index,1,count_i],
    performance_array[aux_index,2,count_i],
    performance_array[aux_index,3,count_i],
    performance_array[aux_index,4,count_i],
    performance_array[aux_index,5,count_i],
    performance_array[aux_index,6,count_i],
    performance_array[aux_index,7,count_i],
    performance_array[aux_index,8,count_i],
    performance_array[aux_index,9,count_i],
    performance_array[aux_index,10,count_i],
    performance_array[aux_index,11,count_i],

```

```

performance_array[aux_index,12,count_i],
performance_array[aux_index,13,count_i],
performance_array[aux_index,14,count_i],
performance_array[aux_index,15,count_i],
performance_array[aux_index,16,count_i],
performance_array[aux_index,17,count_i],
performance_array[aux_index,18,count_i],
performance_array[aux_index,19,count_i],
performance_array[aux_index,20,count_i],
amplitude_min_train,amplitude_max_train,amplitude_max_train-amplitude_min_train,
amplitude_min_test,amplitude_max_test,amplitude_max_test-amplitude_min_test,mean(errors),
sep=";",file = paste(work_dir,"Experiments/Errors/",p,"-scaled-",sc,"-Performance_Array",paste(topnn,collapse = '-'),".txt",sep=""),l,append = TRUE, sep = "\t\n")
str_res="Volume de Negócios"
tmp_less_5 <- errors<0.05
tmp_less_10 <- 0.05<errors & errors<0.10
tmp_less_20 <- 0.10<=errors & errors<0.20
tmp_less_30 <- 0.20<=errors & errors<0.30
tmp_other <- errors>=0.30
color_dot=NULL
color_dot[tmp_less_5]= 'limegreen'
color_dot[tmp_less_10]='lightseagreen'
color_dot[tmp_less_20]='darkblue'
color_dot[tmp_less_30]='orange'
color_dot[tmp_other]='red'
count=count+1
print(paste("C-count: ",count))
if (TRUE){
  setwd(paste(work_dir,"Experiments/Images",sep = ""))
  jpeg(filename=paste(p,"scaled",sc,count,financial_result,c,j,s,"AG",paste(topnn,collapse = '-'),".jpg",sep="-"), width=2400, height=2400,
res = 600) #, pointsize = 20
  plot(ttt$y,pr.nn,col=color_dot,main=str_res,pch=16,cex=0.5, sub=paste(title," ",("j,"),sep=""), ylim=c(ymin,ymax),
xlim=c(xmin,xmax),ylab="Previsão",xlab="Real")
  abline(0,1,lwd=1.5,lty = 2,col = "black")
  abline(0,1.30,lwd=1,lty = 3,col = "orange")
  abline(0,0.70,lwd=1,lty = 3,col = "orange")
  dev.off()
}
}
}
}
if (TRUE){
  count_c=0
  for (c in c(1:n_experiments)){
    for(i in financial_result) {
      for (j in algorithms){
        setwd(paste(work_dir,"Experiments/Errors",sep = ""))
        f_name=paste(p,"scaled",sc,"All_Errors-",j,paste(topnn,collapse = '-'),".txt")
        for (s in sgroups){
          count_c=count_c+1
          #print(paste("Write",c,i,j,s,count_c,sep=" :: "))
          for (e in c(1:length(errors_list[[count_c]][[7]]))){
            write(paste(c,count_c,e,errors_list[[count_c]][[1]], errors_list[[count_c]][[2]], errors_list[[count_c]][[3]],
errors_list[[count_c]][[4]],errors_list[[count_c]][[5]][e], errors_list[[count_c]][[6]][e], errors_list[[count_c]][[7]][e],
errors_list[[count_c]][[8]][e],sep=";",file = f_name,l,append = TRUE, sep = "\t\n")
          }
        }
      }
    }
  }
}
}
setwd(work_dir)
save.image(paste("Workspace-",p,"-",sc,".RData",sep=""))
}#Scaled
}#Projects

```

## Modelo MEGlobal

```

#Loading needed Libraries
library(readxl)
library(dplyr)
library(neuralnet)

#Attributes
topnn=c(256,256,128,32)
set.seed(110)
n_inputs=11
financial_result="VN"
n_results=1
n_experiments=1
#Setting Working Directory
work_dir="C:/Users/BlueUser/Documents/RStudio/Single/Exp III R Studio Global 2013-2014-2015/"
#NeuralNet ANN Algorithms
algorithms=c("rprop+", "rprop-", "sag")
n_algorithms=length(algorithms)
#Load Data
input <- read.csv(paste(work_dir,"Data/Data_Global_total.csv",sep=""), header=TRUE, sep=",")
index <- sample(1:nrow(input),round(0.7*nrow(input)))
train <- input[index,]
test <- input[-index,]
n_samples_train=nrow(train)
n_samples_test=nrow(test)
print(paste("NSamples Train: ",n_samples_train," NSamples Test: ",n_samples_test))
#Groups for Neural Net Testing
#train - Training Set
#test - Test Set
sgroups=c("test","train")
n_groups=length(sgroups)
performance_array=array(0,dim=c(n_groups*n_algorithms,20,n_results))
errors_list<-list()
print("Start Processing ....")
count=0
str_aux_i="No Value"
#Prepare NN formula
n <- names(train[,1:n_inputs])
f <- as.formula(paste("y ~", paste(n[1:n_inputs], collapse = " + ")))
count_i=0
for (c in c(1)) {
  count_i=count_i+1
  count_algorithms=0
  for (j in algorithms) {
    count_algorithms=count_algorithms+1
    title=paste(str_aux_i,j,collapse="-")
    formatted_train=train[1:n_samples_train,1:11]
    formatted_test=test[1:n_samples_test,1:11]
    formatted_all=rbind(train[1:n_samples_train,1:11],test[1:n_samples_test,1:11])
    t_train=as.data.frame(t(scale(t(formatted_train), center = FALSE, scale = array(9,dim=n_samples_train))))#rowSums(abs(formatted_train))))
    t_test=as.data.frame(t(scale(t(formatted_test), center = FALSE, scale = array(9,dim=n_samples_test))))#rowSums(abs(formatted_test))))
    t_train$y=train$y
    t_test$y=test$y
    train=t_train
    test=t_test
    nn <- neuralnet(f,data=train,hidden=topnn,err.fct="sse",stepmax=2.5*1e+05,algorithm = j, act.fct= "logistic", threshold = 0.03, learningrate =
0.9, linear.output=TRUE)
    count_sgroups=0
    for (s in sgroups) {
      count_sgroups=count_sgroups+1
      if (count_sgroups==1) {
        ttt<-test
        title="Conjunto Teste"
      }
      if (count_sgroups==2) {
        ttt<-train
        title="Conjunto Treino"
      }
    }
    pr.nn <- compute(nn,ttt[,1:n_inputs])#11))
    prnn <- pr.nn$net.result
    amplitude_min_train=min(ttt$y)
    amplitude_max_train=max(ttt$y)
    amplitude_min_test=min(prnn_)
    amplitude_max_test=max(prnn_)
    xmin=0
    xmax=max(max(ttt$y),max(prnn_))
    ymin=0
  }
}

```

```

ymax=xmax

errors <- (abs(ttt$y - prnn ))/(ttt$y) #in %
quadratic_errors <- (abs(ttt$y - prnn )^2)
errors_list<-c(errors_list,list(list(c,1,j,s,data.matrix(ttt$y),prnn_errors,quadratic_errors)))
average_error <- mean(errors)
count_less_5=sum(abs(errors) < 0.05)
count_less_10=sum(abs(errors) < 0.10)
count_less_20=sum(abs(errors) < 0.20)
count_less_25=sum(abs(errors) < 0.30)
count_less_40=sum(abs(errors) < 0.40)
count_less_50=sum(abs(errors) < 0.50)
count_more_50=sum(abs(errors) >= 0.50)
count_100=sum(abs(errors) >= 0)
performance_array=array(0,dim=c(n_groups*n_algorithms,20,n_results))
aux_index=(count_algorithms-1)*n_groups+count_sgroups
performance_array[aux_index,1,count_i]=count_sgroups
performance_array[aux_index,2,count_i]=count_algorithms
performance_array[aux_index,3,count_i]=performance_array[aux_index,3,count_i]+count_less_5
performance_array[aux_index,4,count_i]=performance_array[aux_index,4,count_i]+count_less_10
performance_array[aux_index,5,count_i]=performance_array[aux_index,5,count_i]+count_less_20
performance_array[aux_index,6,count_i]=performance_array[aux_index,6,count_i]+count_less_25
performance_array[aux_index,7,count_i]=performance_array[aux_index,7,count_i]+count_less_40
performance_array[aux_index,8,count_i]=performance_array[aux_index,8,count_i]+count_less_50
performance_array[aux_index,9,count_i]=performance_array[aux_index,9,count_i]+count_more_50
performance_array[aux_index,10,count_i]=performance_array[aux_index,10,count_i]+count_100
performance_array[aux_index,11,count_i]=performance_array[aux_index,11,count_i]+average_error*count_100
performance_array[aux_index,12,count_i]=performance_array[aux_index,3,count_i]/performance_array[aux_index,10,count_i]
performance_array[aux_index,13,count_i]=performance_array[aux_index,4,count_i]/performance_array[aux_index,10,count_i]
performance_array[aux_index,14,count_i]=performance_array[aux_index,5,count_i]/performance_array[aux_index,10,count_i]
performance_array[aux_index,15,count_i]=performance_array[aux_index,6,count_i]/performance_array[aux_index,10,count_i]
performance_array[aux_index,16,count_i]=performance_array[aux_index,7,count_i]/performance_array[aux_index,10,count_i]
performance_array[aux_index,17,count_i]=performance_array[aux_index,8,count_i]/performance_array[aux_index,10,count_i]
performance_array[aux_index,18,count_i]=performance_array[aux_index,9,count_i]/performance_array[aux_index,10,count_i]
performance_array[aux_index,19,count_i]=performance_array[aux_index,10,count_i]/performance_array[aux_index,10,count_i]
performance_array[aux_index,20,count_i]=performance_array[aux_index,11,count_i]/performance_array[aux_index,10,count_i]

write(paste(performance_array[aux_index,1,count_i],
performance_array[aux_index,2,count_i],
performance_array[aux_index,3,count_i],
performance_array[aux_index,4,count_i],
performance_array[aux_index,5,count_i],
performance_array[aux_index,6,count_i],
performance_array[aux_index,7,count_i],
performance_array[aux_index,8,count_i],
performance_array[aux_index,9,count_i],
performance_array[aux_index,10,count_i],
performance_array[aux_index,11,count_i],
performance_array[aux_index,12,count_i],
performance_array[aux_index,13,count_i],
performance_array[aux_index,14,count_i],
performance_array[aux_index,15,count_i],
performance_array[aux_index,16,count_i],
performance_array[aux_index,17,count_i],
performance_array[aux_index,18,count_i],
performance_array[aux_index,19,count_i],
performance_array[aux_index,20,count_i],
amplitude_min_train,amplitude_max_train,amplitude_max_train-amplitude_min_train,
amplitude_min_test,amplitude_max_test,amplitude_max_test-amplitude_min_test,mean(errors),
sep=","),file = paste(work_dir,"Experiments/Errors/Performance_Array",paste(topnn,collapse = '-'),".txt",sep=""),1,append = TRUE, sep
= "\t\n")
str_res="Volume de Negócios"
tmp_less_5 <- errors<0.05
tmp_less_10 <- 0.05<errors & errors<0.10
tmp_less_20 <- 0.10<=errors & errors<0.20
tmp_less_30 <- 0.20<=errors & errors<0.30
tmp_other <- errors>=0.30
color_dot=NULL
color_dot[tmp_less_5]='limegreen'
color_dot[tmp_less_10]='lightseagreen'
color_dot[tmp_less_20]='darkblue'
color_dot[tmp_less_30]='orange'
color_dot[tmp_other]='red'
count=count+1
print(paste("C-count: ",count))

if (TRUE){
setwd(work_dir,"Experiments/Images",sep = "")
jpeg(filename=paste(count,financial_result,c,j,s,"AG",paste(topnn,collapse = '-'),".jpg",sep="-"), width=2400, height=2400, res = 600)
plot(ttt$y,prnn,col=color_dot,main=str_res,pch=16,cex=0.5, sub=paste(title," ",("j,"),sep=""), ylim=c(ymin,ymax),
xlim=c(xmin,xmax),ylab="Previsão",xlab="Real")

```

```

abline(0,1,lwd=1.5,lty = 2,col = "black")
abline(0,1.30,lwd=1,lty = 3,col = "orange")
abline(0,0.70,lwd=1,lty = 3,col = "orange")
dev.off()
}
}
}
}

if (TRUE){ #comment
count_c=0
for (c in c(1:n_experiments)){
  for(i in financial_result) {
    for (j in algorithms){
      setwd(paste(work_dir,"Experiments/Errors",sep = ""))
      f_name=paste("All_Errors-",j,paste(topnn,collapse = '-'),".txt")
      for (s in sgroups){
        count_c=count_c+1
        for (e in c(1:length(errors_list[[count_c]][[7]]))){
          write(paste(c,count_c,e,errors_list[[count_c]][[1]], errors_list[[count_c]][[2]], errors_list[[count_c]][[3]],
errors_list[[count_c]][[4]],errors_list[[count_c]][[5]][e], errors_list[[count_c]][[6]][e], errors_list[[count_c]][[7]][e],
errors_list[[count_c]][[8]][e],sep=";"),file = f_name,l,append = TRUE, sep = "\t\n")
        }
      }
    }
  }
}
}
}
}

```

### ***Algoritmo AVG6 (Variante Desenvolvida)***

Modelos ME13, ME14, ME15, ME13T14, ME14T15

```

#Loading needed Libraries
library(readxl)
library(dplyr)
library(neuralnet)

#Attributes
topnn=c(256,256,128,32)
set.seed(110)
n_inputs=11
financial_result="VN"
n_results=1
n_experiments=1
projects=c("Exp II RStudio 2013","Exp II RStudio 2014","Exp II RStudio 2015","Exp II RStudio 2013-2014","Exp II RStudio 2014-2015")
scaled=c("AVG6")

for (p in projects) {

for (sc in scaled){
  #Setting Working Directory
  work_dir=paste("Z:/Experiments/",p,"/",sep="")

  #NeuralNet ANN Algorithms
  algorithms=c("triplex_avg")
  n_algorithms=length(algorithms)

  #Load Data
  train <- read.csv(paste(work_dir,"Data/Data_train.csv",sep=""), header=TRUE, sep=",")
  test <- read.csv(paste(work_dir,"Data/Data_evaluation.csv",sep=""), header=TRUE, sep=",")
  ftrain=train
  fttest=test
  n_samples_train=nrow(train)
  n_samples_test=nrow(test)
  #Groups for Neural Net Testing
  #train - Training Set
  #test - Test Set
  sgroups=c("test","train")
  n_groups=length(sgroups)
  performance_array=array(0,dim=c(n_groups*n_algorithms,20,n_results))
  errors_list<-list()
  print("Start Processing ....")
  count=0
  str_aux_i="No_Value"

```

```

#Prepare NN formula
n <- names(train[,1:n_inputs])
f <- as.formula(paste("y ~", paste(n[!n %in% "y"], collapse = " + ")))

count_i=0
for (c in c(1)){
  count_i=count_i+1
  count_algorithms=0
  for (j in algorithms) {
    train=ftrain
    test=ftest
    count_algorithms=count_algorithms+1
    title=paste(str_aux_i,j,collapse="-")
    formatted_train=train[1:n_samples_train,1:11]
    formatted_test=test[1:n_samples_test,1:11]
    formatted_all=rbind(train[1:n_samples_train,1:11],test[1:n_samples_test,1:11])
    t_train1=as.data.frame(t(scale(t(formatted_train), center = FALSE, scale = array(18,dim=n_samples_train))))
    t_test1=as.data.frame(t(scale(t(formatted_test), center = FALSE, scale = array(18,dim=n_samples_test))))
    t_train2=as.data.frame(t(scale(t(formatted_train), center = FALSE, scale = rowSums(abs(formatted_train)*2))))
    t_test2=as.data.frame(t(scale(t(formatted_test), center = FALSE, scale = rowSums(abs(formatted_test)*2))))
    t_train1$y=train$y
    t_test1$y=test$y
    t_train2$y=train$y
    t_test2$y=test$y
    train_aux1=t_train1
    test_aux1=t_test1
    train_aux2=t_train2
    test_aux2=t_test2

    nn1 <- neuralnet(f,data=train_aux1,hidden=topnn,err.fct="sse",stepmax=5*1e+02,algorithm = "rprop+", act.fct= "logistic", threshold = 0.03,
learningrate = 0.9, linear.output=TRUE)
    nn2 <- neuralnet(f,data=train_aux1,hidden=topnn,err.fct="sse",stepmax=5*1e+02,algorithm = "rprop-", act.fct= "logistic", threshold = 0.03,
learningrate = 0.9, linear.output=TRUE)
    nn3 <- neuralnet(f,data=train_aux1,hidden=topnn,err.fct="sse",stepmax=5*1e+02,algorithm = "sag", act.fct= "logistic", threshold = 0.03,
learningrate = 0.9, linear.output=TRUE)
    nn4 <- neuralnet(f,data=train_aux2,hidden=topnn,err.fct="sse",stepmax=5*1e+02,algorithm = "rprop+", act.fct= "logistic", threshold = 0.03,
learningrate = 0.9, linear.output=TRUE)
    nn5 <- neuralnet(f,data=train_aux2,hidden=topnn,err.fct="sse",stepmax=5*1e+02,algorithm = "rprop-", act.fct= "logistic", threshold = 0.03,
learningrate = 0.9, linear.output=TRUE)
    nn6 <- neuralnet(f,data=train_aux2,hidden=topnn,err.fct="sse",stepmax=5*1e+02,algorithm = "sag", act.fct= "logistic", threshold = 0.03,
learningrate = 0.9, linear.output=TRUE)
    print(paste("FINISHED TRAINNING",p,j,sep=":: "))

    count_sgroups=0
    for (s in sgroups){
      count_sgroups=count_sgroups+1
      if (s=="test") {
        ttt<-test_aux1
        ttt1<-test_aux1
        ttt2<-test_aux2
        title="Conjunto Teste"
      }
      if (s=="train") {
        ttt<-train_aux1
        ttt1<-train_aux1
        ttt2<-train_aux2
        title="Conjunto Treino"
      }
      pr1.nn <- compute(nn1,ttt1[,1:n_inputs])
      pr2.nn <- compute(nn2,ttt1[,1:n_inputs])
      pr3.nn <- compute(nn3,ttt1[,1:n_inputs])
      pr4.nn <- compute(nn4,ttt2[,1:n_inputs])
      pr5.nn <- compute(nn5,ttt2[,1:n_inputs])
      pr6.nn <- compute(nn6,ttt2[,1:n_inputs])

      pr.nn_ <- (pr1.nn$net.result+pr2.nn$net.result+pr3.nn$net.result+pr4.nn$net.result+pr5.nn$net.result+pr6.nn$net.result)/6

      amplitude_min_train=min(ttt1$y)
      amplitude_max_train=max(ttt1$y)
      amplitude_min_test=min(pr.nn_)
      amplitude_max_test=max(pr.nn_)
      xmin=0
      xmax=max(max(ttt1$y),max(pr.nn_))
      ymin=0
      ymax=xmax
      errors <- (abs(ttt1$y - pr.nn_))/(ttt1$y)
      quadratic_errors <- (abs(ttt1$y - pr.nn_)^2)
      errors_list<-c(errors_list,list(list(c,1,j,s,data.matrix(ttt$y),pr.nn_,errors,quadratic_errors)))
      average_error <- mean(errors)
      count_less_5=sum(abs(errors) < 0.05)
      count_less_10=sum(abs(errors) < 0.10)

```

```

count_less_20=sum(abs(errors) < 0.20)
count_less_25=sum(abs(errors) < 0.30)
count_less_40=sum(abs(errors) < 0.40)
count_less_50=sum(abs(errors) < 0.50)
count_more_50=sum(abs(errors) >= 0.50)
count_100=sum(abs(errors) >= 1)
performance_array=array(0,dim=c(n_groups*n_algorithms,20,n_results))
aux_index=(count_algorithms-1)*n_groups+count_sgroups
performance_array[aux_index,1,count_i]=count_sgroups
performance_array[aux_index,2,count_i]=count_algorithms
performance_array[aux_index,3,count_i]=performance_array[aux_index,3,count_i]+count_less_5
performance_array[aux_index,4,count_i]=performance_array[aux_index,4,count_i]+count_less_10
performance_array[aux_index,5,count_i]=performance_array[aux_index,5,count_i]+count_less_20
performance_array[aux_index,6,count_i]=performance_array[aux_index,6,count_i]+count_less_25
performance_array[aux_index,7,count_i]=performance_array[aux_index,7,count_i]+count_less_40
performance_array[aux_index,8,count_i]=performance_array[aux_index,8,count_i]+count_less_50
performance_array[aux_index,9,count_i]=performance_array[aux_index,9,count_i]+count_more_50
performance_array[aux_index,10,count_i]=performance_array[aux_index,10,count_i]+count_100
performance_array[aux_index,11,count_i]=performance_array[aux_index,11,count_i]+average_error*count_100
performance_array[aux_index,12,count_i]=performance_array[aux_index,3,count_i]/performance_array[aux_index,10,count_i]
performance_array[aux_index,13,count_i]=performance_array[aux_index,4,count_i]/performance_array[aux_index,10,count_i]
performance_array[aux_index,14,count_i]=performance_array[aux_index,5,count_i]/performance_array[aux_index,10,count_i]
performance_array[aux_index,15,count_i]=performance_array[aux_index,6,count_i]/performance_array[aux_index,10,count_i]
performance_array[aux_index,16,count_i]=performance_array[aux_index,7,count_i]/performance_array[aux_index,10,count_i]
performance_array[aux_index,17,count_i]=performance_array[aux_index,8,count_i]/performance_array[aux_index,10,count_i]
performance_array[aux_index,18,count_i]=performance_array[aux_index,9,count_i]/performance_array[aux_index,10,count_i]
performance_array[aux_index,19,count_i]=performance_array[aux_index,10,count_i]/performance_array[aux_index,10,count_i]
performance_array[aux_index,20,count_i]=performance_array[aux_index,11,count_i]/performance_array[aux_index,10,count_i]
write(paste(performance_array[aux_index,1,count_i],
  performance_array[aux_index,2,count_i],
  performance_array[aux_index,3,count_i],
  performance_array[aux_index,4,count_i],
  performance_array[aux_index,5,count_i],
  performance_array[aux_index,6,count_i],
  performance_array[aux_index,7,count_i],
  performance_array[aux_index,8,count_i],
  performance_array[aux_index,9,count_i],
  performance_array[aux_index,10,count_i],
  performance_array[aux_index,11,count_i],
  performance_array[aux_index,12,count_i],
  performance_array[aux_index,13,count_i],
  performance_array[aux_index,14,count_i],
  performance_array[aux_index,15,count_i],
  performance_array[aux_index,16,count_i],
  performance_array[aux_index,17,count_i],
  performance_array[aux_index,18,count_i],
  performance_array[aux_index,19,count_i],
  performance_array[aux_index,20,count_i],
  amplitude_min_train,amplitude_max_train,amplitude_max_train-amplitude_min_train,
  amplitude_min_test,amplitude_max_test,amplitude_max_test-amplitude_min_test,mean(errors),
  sep=","),file=paste(work_dir,"Experiments/Errors/",p,"-scaled-",sc,"-Performance_Array",paste(topnn,collapse = '-'),".txt",sep=""),l,append = TRUE, sep = "\t\n")

str_res="Volume de Negócios"
tmp_less_5 <- errors<0.05
tmp_less_10 <- 0.05<errors & errors<0.10
tmp_less_20 <- 0.10<=errors & errors<0.20
tmp_less_30 <- 0.20<=errors & errors<0.30
tmp_other <- errors>=0.30
color_dot=NULL
color_dot[tmp_less_5]= 'limegreen'
color_dot[tmp_less_10]='lightseagreen'
color_dot[tmp_less_20]='darkblue'
color_dot[tmp_less_30]= 'orange'
color_dot[tmp_other]= 'red'
count=count+1

if (TRUE){
  setwd(paste(work_dir,"Experiments/Images",sep = ""))
  jpeg(filename=paste(p,"scaled",sc,count,financial_result,c,j,s,"AG",paste(topnn,collapse = '-'),".jpg",sep="-"), width=2400, height=2400,
res = 600) #, pointsize = 20
  plot(ttt1$y.pr.nn ,col= color_dot,main=str_res,pch=16,cex=0.5, sub=paste(title," ",("j"),sep=""), ylim=c(ymin,ymax),
xlim=c(xmin,xmax),ylab="Previsão",xlab="Real")
  abline(0,1,lwd=1.5,lty = 2,col = "black")
  abline(0,1.30,lwd=1,lty = 3,col = "orange")
  abline(0,0.70,lwd=1,lty = 3,col = "orange")
  dev.off()
}
}
}

```

```

}

if (TRUE){
  count_c=0
  for (c in c(1:n_experiments)){
    for(i in financial_result) {
      for (j in algorithms){
        setwd(paste(work_dir,"Experiments/Errors",sep = ""))
        f_name=paste(p,"scaled",sc,"All_Errors-",j,paste(topnn,collapse = '-'),".txt")
        for (s in sgroups){
          count_c=count_c+1
          for (e in c(1:length(errors_list[[count_c]][[7]]))){
            write(paste(c,count_c,e,errors_list[[count_c]][[1]], errors_list[[count_c]][[2]], errors_list[[count_c]][[3]],
errors_list[[count_c]][[4]],errors_list[[count_c]][[5]][e], errors_list[[count_c]][[6]][e], errors_list[[count_c]][[7]][e],
errors_list[[count_c]][[8]][e],sep=";",file = f_name,1,append = TRUE, sep = "\t\n")
          }
        }
      }
    }
  }
}

setwd(work_dir)
save.image(paste("Workspace-",p,"-",sc,".RData",sep=""))
}#Scaled
}#Projects

```

## Modelo MEGlobal

```

#Loading needed Libraries
library(readxl)
library(dplyr)
library(neuralnet)

#Attributes
topnn=c(256,256,128,32)
set.seed(110)
n_inputs=11
financial_result="VN"
n_results=1
n_experiments=1
projects=c("Exp III R Studio Global 2013-2014-2015")
scaled=c("AVG6")

for (p in projects) {
  for (sc in scaled){
    #Setting Working Directory
    work_dir=paste("Z:/Experiments/",p,"/",sep="")
    #NeuralNet ANN Algorithms
    algorithms=c("triplex_avg")
    n_algorithms=length(algorithms)
    #Load Data
    input <- read.csv(paste(work_dir,"Data/Data_total.csv",sep=""), header=TRUE, sep=",")
    index <- sample(1:nrow(input),round(0.7*nrow(input)))
    train <- input[index,]
    test <- input[-index,]
    ftrain=train
    fttest=test
    n_samples_train=nrow(train)
    n_samples_test=nrow(test)
    #Groups for Neural Net Testing
    #train - Training Set
    #test - Test Set
    sgroups=c("test","train")
    n_groups=length(sgroups)
    performance_array=array(0,dim=c(n_groups*n_algorithms,20,n_results))
    errors_list<-list()
    print("Start Processing ....")
    count=0
    str_aux_i="No Value"
    #Prepare NN formula
    n <- names(train[,1:n_inputs])
    f <- as.formula(paste("y ~", paste(n[!n %in% "y"], collapse = " + ")))
    count_i=0
  }
}

```



```

for (c in c(1)){
  count_i=count_i+1
  count_algorithms=0
  for (j in algorithms) {
    train=ftrain
    test=ftest
    print(paste("Algorithm: ", j))
    count_algorithms=count_algorithms+1
    title=paste(str_aux_i,j,collapse="-")
    formatted_train=train[1:n_samples_train,1:11]
    formatted_test=test[1:n_samples_test,1:11]
    formatted_all=rbind(train[1:n_samples_train,1:11],test[1:n_samples_test,1:11])
    print("Default Scaled")
    t_train1=as.data.frame(t(scale(t(formatted_train), center = FALSE, scale = array(9,dim=n_samples_train))))#rowSums(abs(formatted_train))))
    t_test1=as.data.frame(t(scale(t(formatted_test), center = FALSE, scale = array(9,dim=n_samples_test))))#rowSums(abs(formatted_test))))
    print("Question Scaled")
    t_train2=as.data.frame(t(scale(t(formatted_train), center = FALSE, scale = rowSums(abs(formatted_train)*3))))
    t_test2=as.data.frame(t(scale(t(formatted_test), center = FALSE, scale = rowSums(abs(formatted_test)*3))))
    t_train1$y=train$y
    t_test1$y=test$y
    t_train2$y=train$y
    t_test2$y=test$y
    train_aux1=t_train1
    test_aux1=t_test1
    train_aux2=t_train2
    test_aux2=t_test2
    nn1 <- neuralnet(f,data=train_aux1,hidden=topnn,err.fct="sse",stepmax=3*1e+02,algorithm = "rprop+", act.fct= "logistic", threshold = 0.03,
learningrate = 0.9, linear.output=TRUE)
    print(paste("TRAINNING",p,j,"NN2",sep=":: "))
    nn2 <- neuralnet(f,data=train_aux1,hidden=topnn,err.fct="sse",stepmax=3*1e+02,algorithm = "rprop-", act.fct= "logistic", threshold = 0.03,
learningrate = 0.9, linear.output=TRUE)
    print(paste("TRAINNING",p,j,"NN3",sep=":: "))
    nn3 <- neuralnet(f,data=train_aux1,hidden=topnn,err.fct="sse",stepmax=3*1e+02,algorithm = "sag", act.fct= "logistic", threshold = 0.03,
learningrate = 0.9, linear.output=TRUE)
    print(paste("TRAINNING",p,j,"NN4",sep=":: "))
    nn4 <- neuralnet(f,data=train_aux2,hidden=topnn,err.fct="sse",stepmax=2*1e+03,algorithm = "rprop+", act.fct= "logistic", threshold = 0.03,
learningrate = 0.9, linear.output=TRUE)
    print(paste("TRAINNING",p,j,"NN5",sep=":: "))
    nn5 <- neuralnet(f,data=train_aux2,hidden=topnn,err.fct="sse",stepmax=2*1e+03,algorithm = "rprop-", act.fct= "logistic", threshold = 0.03,
learningrate = 0.9, linear.output=TRUE)
    print(paste("TRAINNING",p,j,"NN6",sep=":: "))
    nn6 <- neuralnet(f,data=train_aux2,hidden=topnn,err.fct="sse",stepmax=2*1e+03,algorithm = "sag", act.fct= "logistic", threshold = 0.03,
learningrate = 0.9, linear.output=TRUE)
    count_sgroups=0
    for (s in sgroups){
      count_sgroups=count_sgroups+1
      if (s=="test") {
        ttt<-test_aux1
        ttt1<-test_aux1
        ttt2<-test_aux2
        title="Conjunto Teste"
      }
      if (s=="train") {
        ttt<-train_aux1
        ttt1<-train_aux1
        ttt2<-train_aux2
        title="Conjunto Treino"
      }
    }
    pr1.nn <- compute(nn1,ttt1[,1:n_inputs])#11))
    pr2.nn <- compute(nn2,ttt1[,1:n_inputs])
    pr3.nn <- compute(nn3,ttt1[,1:n_inputs])
    pr4.nn <- compute(nn4,ttt2[,1:n_inputs])
    pr5.nn <- compute(nn5,ttt2[,1:n_inputs])
    pr6.nn <- compute(nn6,ttt2[,1:n_inputs])
    pr.nn_ <- (pr1.nn$net.result+pr2.nn$net.result+pr3.nn$net.result+pr4.nn$net.result+pr5.nn$net.result+pr6.nn$net.result)/6
    amplitude_min_train=min(ttt1$y)
    amplitude_max_train=max(ttt1$y)
    amplitude_min_test=min(pr.nn_)
    amplitude_max_test=max(pr.nn_)
    xmin=0
    xmax=max(max(ttt1$y),max(pr.nn_))
    ymin=0
    ymax=xmax
    errors <- (abs(ttt1$y - pr.nn_))/(ttt1$y) #in %
    quadratic_errors <- (abs(ttt1$y - pr.nn_)^2)
    errors_list<-c(errors_list,list(list(c,1,j,s,data.matrix(ttt$y),pr.nn_errors,quadratic_errors)))
    average_error <- mean(errors)
    count_less_5=sum(abs(errors) < 0.05)
    count_less_10=sum(abs(errors) < 0.10)
    count_less_20=sum(abs(errors) < 0.20)
    count_less_25=sum(abs(errors) < 0.30)
  }
}

```

```

count_less_40=sum(abs(errors) <0.40)
count_less_50=sum(abs(errors) <0.50)
count_more_50=sum(abs(errors) >= 0.50)
count_100=sum(abs(errors) >= 0)
performance_array=array(0,dim=c(n_groups*n_algorithms,20,n_results))
aux_index=(count_algorithms-1)*n_groups+count_sgroups
performance_array[aux_index,1,count_i]=count_sgroups
performance_array[aux_index,2,count_i]=count_algorithms
performance_array[aux_index,3,count_i]=performance_array[aux_index,3,count_i]+count_less_5
performance_array[aux_index,4,count_i]=performance_array[aux_index,4,count_i]+count_less_10
performance_array[aux_index,5,count_i]=performance_array[aux_index,5,count_i]+count_less_20
performance_array[aux_index,6,count_i]=performance_array[aux_index,6,count_i]+count_less_25
performance_array[aux_index,7,count_i]=performance_array[aux_index,7,count_i]+count_less_40
performance_array[aux_index,8,count_i]=performance_array[aux_index,8,count_i]+count_less_50
performance_array[aux_index,9,count_i]=performance_array[aux_index,9,count_i]+count_more_50
performance_array[aux_index,10,count_i]=performance_array[aux_index,10,count_i]+count_100
performance_array[aux_index,11,count_i]=performance_array[aux_index,11,count_i]+average_error*count_100
performance_array[aux_index,12,count_i]=performance_array[aux_index,3,count_i]/performance_array[aux_index,10,count_i]
performance_array[aux_index,13,count_i]=performance_array[aux_index,4,count_i]/performance_array[aux_index,10,count_i]
performance_array[aux_index,14,count_i]=performance_array[aux_index,5,count_i]/performance_array[aux_index,10,count_i]
performance_array[aux_index,15,count_i]=performance_array[aux_index,6,count_i]/performance_array[aux_index,10,count_i]
performance_array[aux_index,16,count_i]=performance_array[aux_index,7,count_i]/performance_array[aux_index,10,count_i]
performance_array[aux_index,17,count_i]=performance_array[aux_index,8,count_i]/performance_array[aux_index,10,count_i]
performance_array[aux_index,18,count_i]=performance_array[aux_index,9,count_i]/performance_array[aux_index,10,count_i]
performance_array[aux_index,19,count_i]=performance_array[aux_index,10,count_i]/performance_array[aux_index,10,count_i]
performance_array[aux_index,20,count_i]=performance_array[aux_index,11,count_i]/performance_array[aux_index,10,count_i]
write(paste(performance_array[aux_index,1,count_i],
performance_array[aux_index,2,count_i],
performance_array[aux_index,3,count_i],
performance_array[aux_index,4,count_i],
performance_array[aux_index,5,count_i],
performance_array[aux_index,6,count_i],
performance_array[aux_index,7,count_i],
performance_array[aux_index,8,count_i],
performance_array[aux_index,9,count_i],
performance_array[aux_index,10,count_i],
performance_array[aux_index,11,count_i],
performance_array[aux_index,12,count_i],
performance_array[aux_index,13,count_i],
performance_array[aux_index,14,count_i],
performance_array[aux_index,15,count_i],
performance_array[aux_index,16,count_i],
performance_array[aux_index,17,count_i],
performance_array[aux_index,18,count_i],
performance_array[aux_index,19,count_i],
performance_array[aux_index,20,count_i],
amplitude_min_train,amplitude_max_train,amplitude_max_train-amplitude_min_train,
amplitude_min_test,amplitude_max_test,amplitude_max_test-amplitude_min_test,mean(errors),
sep=","),file = paste(work_dir,"Experiments/Errors/",p,"-scaled-",sc,"-Performance_Array",paste(topnn,collapse = '-'),".txt",sep=""),1,append = TRUE, sep = "\t\n")
str_res="Volume de Negócios"
tmp_less_5 <- errors<0.05
tmp_less_10 <- 0.05<errors & errors<0.10
tmp_less_20 <- 0.10<=errors & errors<0.20
tmp_less_30 <- 0.20<=errors & errors<0.30
tmp_other <- errors>=0.30
color_dot=NULL
color_dot[tmp_less_5]= 'limegreen'
color_dot[tmp_less_10]= 'lightseagreen'
color_dot[tmp_less_20]= 'darkblue'
color_dot[tmp_less_30]= 'orange'
color_dot[tmp_other]= 'red'
count=count+1
print (paste("C-count: ",count))
if (TRUE){
setwd(paste(work_dir,"Experiments/Images",sep = ""))
jpeg(filename=paste(p,"scaled",sc,count,financial_result,c,j,s,"AG",paste(topnn,collapse = '-'),".jpg",sep="-"), width=2400, height=2400,
res = 600) #, fontsize = 20
plot(ttt1$y.pr.nn ,col= color_dot,main=str_res,pch=16,cex=0.5, sub=paste(title," ",("j,j"),sep=""), ylim=c(ymin,ymax),
xlim=c(xmin,xmax),ylab="Previsão",xlab="Real")
abline(0,1,lwd=1.5,lty = 2,col = "black")
abline(0,1.30,lwd=1,lty = 3,col = "orange")
abline(0,0.70,lwd=1,lty = 3,col = "orange")
dev.off()
}
}
}
}

if (TRUE){
count_c=0

```

```

for (c in c(1:n_experiments)){
  for(i in financial_result) {
    for (j in algorithms){
      setwd(paste(work_dir,"Experiments/Errors",sep = ""))
      f_name=paste(p,"scaled",sc,"All_Errors-",j,paste(topnn,collapse = '-'),".txt")
      for (s in sgroups){
        count_c=count_c+1
        for (e in c(1:length(errors_list[[count_c]][[7]]))){
          write(paste(c,count_c,e,errors_list[[count_c]][[1]], errors_list[[count_c]][[2]], errors_list[[count_c]][[3]],
errors_list[[count_c]][[4]],errors_list[[count_c]][[5]][e], errors_list[[count_c]][[6]][e], errors_list[[count_c]][[7]][e],
errors_list[[count_c]][[8]][e],sep=";",file = f_name,1,append = TRUE, sep = "\t\n")
        }
      }
    }
  }
}

}
setwd(work_dir)
save.image(paste("Workspace-",p,"-",sc,".RData",sep=""))
}#Scaled
}#Projects

```

## Algoritmo RProp Avg (Variante Desenvolvida)

### Todos os Modelos (Genérico)

```

#Loading needed Libraries
library(readxl)
library(dplyr)
library(neuralnet)

#Attributes
topnn=c(256,256,128,32)
set.seed(110)
n_inputs=11
financial_result="VN"
n_results=1
n_experiments=1
#Setting Working Directory
work_dir="Z:/Experiment/"
#NeuralNet ANN Algorithms
algorithms=c("rprop-var")
n_algorithms=length(algorithms)
#Load Data
train <- read.csv(paste(work_dir,"Data/Data_train.csv",sep=""), header=TRUE, sep=",")
test <- read.csv(paste(work_dir,"Data/Data_evaluation.csv",sep=""), header=TRUE, sep=",")
n_samples_train=nrow(train)
n_samples_test=nrow(test)
#Groups for Neural Net Testing
#train - Trainning Set
#test - Test Set
sgroups=c("test","train")
n_groups=length(sgroups)
performance_array=array(0,dim=c(n_groups*n_algorithms,20,n_results))
errors_list<-list()
print("Start Processing ....")
count=0
str_aux_i="No_Value"
#Prepare NN formula
n <- names(train[,1:n_inputs])
f <- as.formula(paste("y ~", paste(n[1:n %in% "y"], collapse = " + ")))
count_i=0
for (c in c(1)){
  count_i=count_i+1
  count_algorithms=0
  for (j in algorithms) {
    count_algorithms=count_algorithms+1
    title=paste(str_aux_i,j,collapse="-")
    formatted_train=train[1:n_samples_train,1:11]
    formatted_test=test[1:n_samples_test,1:11]
    formatted_all=rbind(train[1:n_samples_train,1:11],test[1:n_samples_test,1:11])
    t_train=as.data.frame(t(scale(t(formatted_train), center = FALSE, scale = array(9,dim=n_samples_train))))#rowSums(abs(formatted_train))))
    t_test=as.data.frame(t(scale(t(formatted_test), center = FALSE, scale = array(9,dim=n_samples_test))))#rowSums(abs(formatted_test))))
    t_train$y=train$y

```

```

t_test$y=test$y
train=t_train
test=t_test
nn <- neuralnet(f,data=train,hidden=topnn,err.fct="sse",stepmax=2.5*1e+05,algorithm = "rprop+", act.fct= "logistic", threshold = 0.03,
learningrate = 0.9, linear.output=TRUE)
nn2 <- neuralnet(f,data=train,hidden=topnn,err.fct="sse",stepmax=2.5*1e+05,algorithm = "rprop-", act.fct= "logistic", threshold = 0.03,
learningrate = 0.9, linear.output=TRUE)
count_sgroups=0
for (s in sgroups){
  count_sgroups=count_sgroups+1
  if (count_sgroups==1) {
    ttt<-test
    title="Conjunto Teste"
  }
  if (count_sgroups==2) {
    ttt<-train
    title="Conjunto Treino"
  }
  pr.nn <- compute(nn,ttt[,1:n_inputs])#11))
  pr2.nn <- compute(nn2,ttt[,1:n_inputs])
  prnn <- (pr.nn$net.result+pr2.nn$net.result)/2
  amplitude_min_train=min(ttt$y)
  amplitude_max_train=max(ttt$y)
  amplitude_min_test=min(prnn_)
  amplitude_max_test=max(prnn_)
  xmin=0
  xmax=max(max(ttt$y),max(prnn_))
  ymin=0
  ymax=xmax
  errors <- (abs(ttt$y - prnn_))/(ttt$y) #in %
  quadratic_errors <- (abs(ttt$y - prnn_)^2)
  errors_list<-c(errors_list,list(c(1,j,s,data.matrix(ttt$y),prnn_,errors,quadratic_errors)))
  average_error <- mean(errors)
  count_less_5=sum(abs(errors) < 0.05)
  count_less_10=sum(abs(errors) < 0.10)
  count_less_20=sum(abs(errors) < 0.20)
  count_less_25=sum(abs(errors) < 0.30)
  count_less_40=sum(abs(errors) < 0.40)
  count_less_50=sum(abs(errors) < 0.50)
  count_more_50=sum(abs(errors) >= 0.50)
  count_100=sum(abs(errors) >= 0)
  performance_array=array(0,dim=c(n_groups*n_algorithms,20,n_results))
  aux_index=(count_algorithms-1)*n_groups+count_sgroups
  performance_array[aux_index,1,count_i]=count_sgroups
  performance_array[aux_index,2,count_i]=count_algorithms
  performance_array[aux_index,3,count_i]=performance_array[aux_index,3,count_i]+count_less_5
  performance_array[aux_index,4,count_i]=performance_array[aux_index,4,count_i]+count_less_10
  performance_array[aux_index,5,count_i]=performance_array[aux_index,5,count_i]+count_less_20
  performance_array[aux_index,6,count_i]=performance_array[aux_index,6,count_i]+count_less_25
  performance_array[aux_index,7,count_i]=performance_array[aux_index,7,count_i]+count_less_40
  performance_array[aux_index,8,count_i]=performance_array[aux_index,8,count_i]+count_less_50
  performance_array[aux_index,9,count_i]=performance_array[aux_index,9,count_i]+count_more_50
  performance_array[aux_index,10,count_i]=performance_array[aux_index,10,count_i]+count_100
  performance_array[aux_index,11,count_i]=performance_array[aux_index,11,count_i]+average_error*count_100
  performance_array[aux_index,12,count_i]=performance_array[aux_index,3,count_i]/performance_array[aux_index,10,count_i]
  performance_array[aux_index,13,count_i]=performance_array[aux_index,4,count_i]/performance_array[aux_index,10,count_i]
  performance_array[aux_index,14,count_i]=performance_array[aux_index,5,count_i]/performance_array[aux_index,10,count_i]
  performance_array[aux_index,15,count_i]=performance_array[aux_index,6,count_i]/performance_array[aux_index,10,count_i]
  performance_array[aux_index,16,count_i]=performance_array[aux_index,7,count_i]/performance_array[aux_index,10,count_i]
  performance_array[aux_index,17,count_i]=performance_array[aux_index,8,count_i]/performance_array[aux_index,10,count_i]
  performance_array[aux_index,18,count_i]=performance_array[aux_index,9,count_i]/performance_array[aux_index,10,count_i]
  performance_array[aux_index,19,count_i]=performance_array[aux_index,10,count_i]/performance_array[aux_index,10,count_i]
  performance_array[aux_index,20,count_i]=performance_array[aux_index,11,count_i]/performance_array[aux_index,10,count_i]
  write(paste(performance_array[aux_index,1,count_i],
    performance_array[aux_index,2,count_i],
    performance_array[aux_index,3,count_i],
    performance_array[aux_index,4,count_i],
    performance_array[aux_index,5,count_i],
    performance_array[aux_index,6,count_i],
    performance_array[aux_index,7,count_i],
    performance_array[aux_index,8,count_i],
    performance_array[aux_index,9,count_i],
    performance_array[aux_index,10,count_i],
    performance_array[aux_index,11,count_i],
    performance_array[aux_index,12,count_i],
    performance_array[aux_index,13,count_i],
    performance_array[aux_index,14,count_i],
    performance_array[aux_index,15,count_i],
    performance_array[aux_index,16,count_i],
    performance_array[aux_index,17,count_i],
    performance_array[aux_index,18,count_i],
    performance_array[aux_index,19,count_i],
    performance_array[aux_index,20,count_i]),

```

```

performance_array[aux_index,19,count_i],
performance_array[aux_index,20,count_i],
amplitude_min_train,amplitude_max_train,amplitude_min_train,
amplitude_min_test,amplitude_max_test,amplitude_max_test-amplitude_min_test,mean(errors),
sep=";",file=paste(work_dir,"Experiments/Errors/Performance_Array",paste(topnn,collapse='-'),".txt",sep=""),1,append=TRUE, sep
="\t\n")
str_res="Volume de Negócios"
tmp_less_5 <- errors<0.05
tmp_less_10 <- 0.05<errors & errors<0.10
tmp_less_20 <- 0.10<=errors & errors<0.20
tmp_less_30 <- 0.20<=errors & errors<0.30
tmp_other <- errors>=0.30
color_dot=NULL
color_dot[tmp_less_5]= 'limegreen'
color_dot[tmp_less_10]='lightseagreen'
color_dot[tmp_less_20]='darkblue'
color_dot[tmp_less_30]='orange'
color_dot[tmp_other]='red'
count=count+1
if(TRUE){
  setwd(paste(work_dir,"Experiments/Images",sep=""))
  jpeg(filename=paste(count,financial_result,c,j,s,"AG",paste(topnn,collapse='-'),".jpg",sep="-"), width=2400, height=2400, res = 600)
  plot(ttt$y,prmn,col=color_dot,main=str_res,pch=16,cex=0.5, sub=paste(title," ",("(",j,")",sep=""), ylim=c(ymin,ymax),
xlim=c(xmin,xmax),ylab="Previsão",xlab="Real")
  abline(0,1,lwd=1.5,lty = 2,col = "black")
  abline(0,1.30,lwd=1,lty = 3,col = "orange")
  abline(0,0.70,lwd=1,lty = 3,col = "orange")
  dev.off()
}
}
}

if(TRUE){ #comment
count_c=0
for (c in c(1:n_experiments)){
  for(i in financial_result) {
    for (j in algorithms){
      setwd(paste(work_dir,"Experiments/Errors",sep=""))
      f_name=paste("All_Errors-",j,paste(topnn,collapse='-'),".txt")
      for (s in sgroups){
        count_c=count_c+1
        #print(paste("Write",c,i,j,s,count_c,sep=" :: "))
        for (e in c(1:length(errors_list[[count_c]][[7]]))){
          write(paste(c,count_c,e,errors_list[[count_c]][[1]], errors_list[[count_c]][[2]], errors_list[[count_c]][[3]],
errors_list[[count_c]][[4]],errors_list[[count_c]][[5]][e], errors_list[[count_c]][[6]][e], errors_list[[count_c]][[7]][e],
errors_list[[count_c]][[8]][e],sep=";",file=f_name,1,append=TRUE, sep = "\t\n")
        }
      }
    }
  }
}
}
}

```

## A.6.2 Árvores de Decisão

### *Todos os Modelos (Genérico)*

```

#Loading needed Libraries
library(readxl)
library(dplyr)
library(rpart)
library(rpart.plot)
#Attributes
require(randomForest)
require(gbm)

topnn=c("AD")
set.seed(110)
n_inputs=11
financial_result="VN"
n_results=1
n_experiments=1
#Setting Working Directory

```

```

work_dir="Z:/Experiment/"
#Algorithms
algorithms=c("s","n")
n_algorithms=length(algorithms)

#Load Data
train <- read.csv(paste(work_dir,"Data/Data_train AD.csv",sep=""), header=TRUE, sep=",")
test <- read.csv(paste(work_dir,"Data/Data_evaluation AD.csv",sep=""), header=TRUE, sep=",")
n_samples_train=nrow(train)
n_samples_test=nrow(test)
print(paste("NSamples Train: ",n_samples_train," NSamples Test: ",n_samples_test))
#Groups for Neural Net Testing
#train - Training Set
#test - Test Set
sgroups=c("test","train")
n_groups=length(sgroups)
performance_array=array(0,dim=c(n_groups*n_algorithms,20,n_results))
errors_list<-list()
print("Start Processing ....")
count=0
str_aux_i="No_Value"

#Prepare AD formula
n <- names(train[,1:n_inputs])
f <- as.formula(paste("y ~", paste(n[!n %in% "y"], collapse = " + ")))
count_i=0
for (c in c(1)) {
  count_i=count_i+1
  count_algorithms=0
  for (j in algorithms) {
    print(paste("Algorithm: ", j))
    count_algorithms=count_algorithms+1
    title=paste(str_aux_i,j,collapse="-")
    formatted_train=train[1:n_samples_train,1:11]
    formatted_test=test[1:n_samples_test,1:11]
    formatted_all=rbind(train[1:n_samples_train,1:11],test[1:n_samples_test,1:11])
    if (j=="s") {
      print("Scaled")
      t_train=as.data.frame(t(scale(t(formatted_train), center = FALSE, scale = array(9,dim=n_samples_train))))#rowSums(abs(formatted_train))))
      t_test=as.data.frame(t(scale(t(formatted_test), center = FALSE, scale = array(9,dim=n_samples_test))))#rowSums(abs(formatted_test))))
    }
    if (j=="n") {
      print("Not Scaled")
      t_train=formatted_train
      t_test=formatted_test
    }
    t_train$y=train$y
    t_test$y=test$y
    trainaux=t_train
    testaux=t_test
    print("TRAINNING")
    tree <- rpart(f,data=trainaux,control=rpart.control(minsplit=3, cp=0.001))
    setwd(paste(work_dir,"Experiments/Images",sep = ""))
    jpeg(filename=paste("tree",count,financial_result,c,j,"AG",paste(topnn,collapse = "-"),".jpg",sep="-"), width=9600, height=9600, res = 600)
    prp(tree)
    dev.off()
    count_sgroups=0
    for (s in sgroups){
      count_sgroups=count_sgroups+1
      if (count_sgroups==1) {
        ttt<-testaux
        title="Conjunto Teste"
      }
      if (count_sgroups==2) {
        ttt<-trainaux
        title="Conjunto Treino"
      }
    }
    pr.nn <- predict(tree, newdata=ttt[,1:n_inputs],n.trees = n.trees)
    prnn <- pr.nn
    prnn <- round(prnn *20)/20
    amplitude_min_train=min(ttt$y)
    amplitude_max_train=max(ttt$y)
    amplitude_min_test=min(prnn_)
    amplitude_max_test=max(prnn_)
    xmin=0
    xmax=max(max(ttt$y),max(prnn_))
    ymin=0
    ymax=xmax
    errors <- (abs(ttt$y - prnn_))/(ttt$y) #in %
    quadratic_errors <- (abs(ttt$y - prnn_)^2)
    errors_list<-c(errors_list,list(list(c,1,j,s,data.matrix(ttt$y),prnn_errors,quadratic_errors)))
  }
}

```

```

average_error <- mean(errors)
count_less_5=sum(abs(errors) < 0.05)
count_less_10=sum(abs(errors) < 0.10)
count_less_20=sum(abs(errors) < 0.20)
count_less_25=sum(abs(errors) < 0.30)
count_less_40=sum(abs(errors) < 0.40)
count_less_50=sum(abs(errors) < 0.50)
count_more_50=sum(abs(errors) >= 0.50)
count_100=sum(abs(errors) >= 0)
performance_array=array(0,dim=c(n_groups*n_algorithms,20,n_results))
aux_index=(count_algorithms-1)*n_groups+count_sgroups
performance_array[aux_index,1,count_i]=count_sgroups
performance_array[aux_index,2,count_i]=count_algorithms
performance_array[aux_index,3,count_i]=performance_array[aux_index,3,count_i]+count_less_5
performance_array[aux_index,4,count_i]=performance_array[aux_index,4,count_i]+count_less_10
performance_array[aux_index,5,count_i]=performance_array[aux_index,5,count_i]+count_less_20
performance_array[aux_index,6,count_i]=performance_array[aux_index,6,count_i]+count_less_25
performance_array[aux_index,7,count_i]=performance_array[aux_index,7,count_i]+count_less_40
performance_array[aux_index,8,count_i]=performance_array[aux_index,8,count_i]+count_less_50
performance_array[aux_index,9,count_i]=performance_array[aux_index,9,count_i]+count_more_50
performance_array[aux_index,10,count_i]=performance_array[aux_index,10,count_i]+count_100
performance_array[aux_index,11,count_i]=performance_array[aux_index,11,count_i]+average_error*count_100
performance_array[aux_index,12,count_i]=performance_array[aux_index,3,count_i]/performance_array[aux_index,10,count_i]
performance_array[aux_index,13,count_i]=performance_array[aux_index,4,count_i]/performance_array[aux_index,10,count_i]
performance_array[aux_index,14,count_i]=performance_array[aux_index,5,count_i]/performance_array[aux_index,10,count_i]
performance_array[aux_index,15,count_i]=performance_array[aux_index,6,count_i]/performance_array[aux_index,10,count_i]
performance_array[aux_index,16,count_i]=performance_array[aux_index,7,count_i]/performance_array[aux_index,10,count_i]
performance_array[aux_index,17,count_i]=performance_array[aux_index,8,count_i]/performance_array[aux_index,10,count_i]
performance_array[aux_index,18,count_i]=performance_array[aux_index,9,count_i]/performance_array[aux_index,10,count_i]
performance_array[aux_index,19,count_i]=performance_array[aux_index,10,count_i]/performance_array[aux_index,10,count_i]
performance_array[aux_index,20,count_i]=performance_array[aux_index,11,count_i]/performance_array[aux_index,10,count_i]

write(paste(performance_array[aux_index,1,count_i],
performance_array[aux_index,2,count_i],
performance_array[aux_index,3,count_i],
performance_array[aux_index,4,count_i],
performance_array[aux_index,5,count_i],
performance_array[aux_index,6,count_i],
performance_array[aux_index,7,count_i],
performance_array[aux_index,8,count_i],
performance_array[aux_index,9,count_i],
performance_array[aux_index,10,count_i],
performance_array[aux_index,11,count_i],
performance_array[aux_index,12,count_i],
performance_array[aux_index,13,count_i],
performance_array[aux_index,14,count_i],
performance_array[aux_index,15,count_i],
performance_array[aux_index,16,count_i],
performance_array[aux_index,17,count_i],
performance_array[aux_index,18,count_i],
performance_array[aux_index,19,count_i],
performance_array[aux_index,20,count_i],
amplitude_min_train,amplitude_max_train,amplitude_max_train-amplitude_min_train,
amplitude_min_test,amplitude_max_test,amplitude_max_test-amplitude_min_test,mean(errors),
sep=";"),file = paste(work_dir,"Experiments/Errors/Performance_Array",paste(topnn,collapse = '-'),".txt",sep=""),1,append = TRUE, sep
= "\t\n")
str_res="Volume de Negócios"
tmp_less_5 <- errors<0.05
tmp_less_10 <- 0.05<errors & errors<0.10
tmp_less_20 <- 0.10<=errors & errors<0.20
tmp_less_30 <- 0.20<=errors & errors<0.30
tmp_other <- errors>=0.30
color_dot=NULL
color_dot[tmp_less_5]='limegreen'
color_dot[tmp_less_10]='lightseagreen'
color_dot[tmp_less_20]='darkblue'
color_dot[tmp_less_30]='orange'
color_dot[tmp_other]='red'
count=count+1

if (TRUE){
setwd(work_dir,"Experiments/Images",sep = "")
jpeg(filename=paste(count,financial_result,c,j,s,"AG",paste(topnn,collapse = '-'),".jpg",sep="-"), width=2400, height=2400, res = 600)
plot(ttt$y,prmn,col=color_dot,main=str_res,pch=16,cex=0.5, sub=paste(title," ",("j,"),sep=""), ylim=c(ymin,ymax),
xlim=c(xmin,xmax),ylab="Previsão",xlab="Real")
abline(0,1,lwd=1.5,lty = 2,col = "black")
abline(0,1.30,lwd=1,lty = 3,col = "orange")
abline(0,0.70,lwd=1,lty = 3,col = "orange")
dev.off()
}
}

```

```

}

if (TRUE){
count_c=0
for (c in c(1:n_experiments)){
  for(i in financial_result) {
    for (j in algorithms){
      setwd(paste(work_dir,"Experiments/Errors",sep = ""))
      f_name=paste("All_Errors-",j,paste(topnn,collapse = '-'),".txt")
      for (s in sgroups){
        count_c=count_c+1
        #print(paste("Write",c,i,j,s,count_c,sep=" :: "))
        for (e in c(1:length(errors_list[[count_c]][[7]]))){
          write(paste(c,count_c,e,errors_list[[count_c]][[1]], errors_list[[count_c]][[2]], errors_list[[count_c]][[3]],
errors_list[[count_c]][[4]],errors_list[[count_c]][[5]][e], errors_list[[count_c]][[6]][e], errors_list[[count_c]][[7]][e],
errors_list[[count_c]][[8]][e],sep=";"),file = f_name,l,append = TRUE, sep = "\t\n")
        }
      }
    }
  }
}
}
}

```